



Approche modulaire pour le suivi temps réel de cibles multi-capteurs pour les applications routières

Laetitia Lamard

► To cite this version:

Laetitia Lamard. Approche modulaire pour le suivi temps réel de cibles multi-capteurs pour les applications routières. Autre. Université Blaise Pascal - Clermont-Ferrand II, 2014. Français. NNT : 2014CLF22477 . tel-01248256

HAL Id: tel-01248256

<https://theses.hal.science/tel-01248256>

Submitted on 4 Jan 2016

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

N ° d'ordre : D.U. 2477

EDSPIC : 662

UNIVERSITÉ BLAISE PASCAL - CLERMONT II

École Doctorale

Sciences Pour l'Ingénieur de Clermont-ferrand

Thèse présentée par :

Laetitia Lamard

en vue de l'obtention du grade de

DOCTEUR D'UNIVERSITÉ

Spécialité : Vision pour la Robotique

**Approche modulaire pour le suivi temps réel de cibles
multi-capteurs pour les applications routières**

Soutenue publiquement le 10 juillet 2014 devant le jury :

Michèle ROMBAUT	Professeur Université Joseph Fourier	Présidente
Véronique BERGE-CHERFAOUI	Maître de Conférences HDR UTC Compiègne	Rapporteur
Fawzi NASHASHIBI	Directeur de Recherche INRIA Rocquencourt	Rapporteur
Jean-Philippe BOYER	Ingénieur de Recherche Renault	Examineur
Jean-Charles NOYER	Professeur LISIC Calais	Examineur
Roland CHAPUIS	Professeur Institut Pascal Clermont-Fd	Directeur de thèse
Johann MOUSAIN	Responsable d'UET Renault	Invité

Remerciements

Ma thèse s’est déroulée en partie à l’Institut Pascal à Clermont-Ferrand, en partie à Renault à Guyancourt dans le service d’aide à la conduite. Avant de remercier les personnes qui m’ont aidée dans ma thèse, j’aimerais remercier Renault SAS et l’ANRT qui ont financé mes travaux.

Tout d’abord, je tiens à remercier Roland Chapuis pour avoir dirigé ma thèse. Sans le connaître avant le début de ma thèse, Roland s’est avéré un directeur remarquable. Suivant mon désir, ma présence à Clermont Ferrand s’est limitée à des moments ponctuels, Roland a rendu ce fonctionnement particulier possible. Il a su me guider et me soutenir dans les moments de doute, tout en me laissant le temps et le plaisir d’être autonome dans mon travail. Sa faculté d’écoute, de pédagogie, de compréhension en font un excellent directeur de thèse, les discussions ont toujours été bénéfiques et prolifiques. Ajouté à ces quelques qualités, je tiens aussi à souligner la facilité avec laquelle il est possible de discuter avec lui, je le remercie encore de sa bonne humeur et de la bonne ambiance de travail qu’il a su instaurer. Les réunions avec Roland ont toujours été un plaisir et l’assurance de conseils avisés. Ensuite, je remercie Jean Philippe pour avoir suivi mes travaux. Merci pour les discussions qui m’ont aidé à mieux comprendre et appréhender les problématiques d’une grande entreprise telle que Renault. Son aide m’a également été précieuse pour l’acquisition des données utiles à mes travaux, il m’a permis d’avoir accès à l’ensemble des moyens d’acquisition et aux capteurs que je souhaitais.

Je remercie avec une grande considération les futurs membres de mon jury de thèse (Fawzi Nashashibi, Véronique Berge Cherfaoui, Michèle Rombaut, et Jean-Pierre Noyer, Johann Mousain et Roland Chapuis) pour avoir accepté et pris le temps d’évaluer mes travaux. Un merci particulier à Fawzi Nashashibi, Véronique Berge Charfaoui pour avoir accepté d’être rapporteurs de ma thèse.

Un grand merci à mes collègues Renault du service ADAS, aux actuels ainsi qu’aux anciens. Je pense aux différentes soirées organisées, aux pots d’arrivés, de départ, ainsi qu’aux

croissants du jeudi. Parmi ces collègues, je me dois de remercier particulièrement Javier Ibanez Guzman, qui sans être officiellement mon encadrant a toujours agi comme tel. Il m’a prodigué de précieux conseils et a toujours eu un avis intéressant et pertinent sur les travaux de recherche. Je me permets de distinguer mes collègues thésards, Clément Zinoune et Alexandre Armand, mes voisins de bureau, ainsi que Stéphanie Lefevre. En plus de m’avoir aidé régulièrement dans mon travail de thèse, avoir relu et corrigé mes papiers, et même avoir résolu certains problèmes théoriques, ils m’ont couramment soutenu dans mes moments de doute ou de stress. Je me souviendrai de nos pauses café, de nos soirées, et de nos semaines de conférence. Nous avons découvert ensemble le monde de la recherche et nous avons appris ensemble à le décoder et à l’apprécier. Plus que des collègues, ce sont devenus pour moi de vrais amis.

Je pense aussi à mes collègues de Clermont-Ferrand, Guillaume, Thomas, David, Claude qui m’ont aidée à décrypter les procédures administratives. Je tiens tout particulièrement à remercier Vanessa Chaudron, qui a facilité ma vie pendant trois ans. Elle a toujours été présente et efficace pour la gestion de mes déplacements à Clermont Ferrand. Cela a toujours été un plaisir de discuter avec elle à chacun de mes voyages. Je remercie particulièrement Clément qui a permis à mes voyages à Clermont d’être agréables. Il m’a par exemple bravement aidé à supporter certains modules de cours.

Plus personnellement, je remercie mes amies et ma famille pour leur soutien inconditionnelle. Mes remerciements les plus profonds vont évidemment à mes parents, qui m’ont toujours encouragée dans mes études. C’est grâce à eux deux que j’ai cet amour des sciences. Ils m’ont toujours laissée libre de mes choix et ont toujours été de bons conseils et modèles. Merci pour la confiance qu’ils m’ont accordée. Un grand merci à mon frère Nicolas, bien qu’étant réservé, je sais que je peux toujours compter sur lui.

Pour finir, je tiens à remercier l’amour de ma vie : Corentin. Il a toujours été là pour moi, du début de ma thèse, à la relecture de mon mémoire. Je le remercie pour son soutien, et sa compréhension. Il m’a permis de relativiser les situations stressantes en prenant un peu de recul. Merci.

Table des matières

1	Introduction et analyse de la problématique	1
1.1	Objectifs : applications ADAS	2
1.1.1	Architecture classique de systèmes d’aide à la conduite	2
1.1.1.1	Perception	2
1.1.1.2	Fusion	2
1.1.1.3	Décision	3
1.1.1.4	Action	3
1.1.2	Applications ADAS	4
1.1.2.1	ACC, DW	4
1.1.2.2	Pré-crash piéton	5
1.1.2.3	Véhicule autonome	5
1.2	Capteurs ADAS	7
1.2.1	Lidar, ou télémètre laser	7
1.2.2	Caméra	9
1.2.2.1	Systèmes Mono-caméra	9
1.2.2.2	Stéréo-vision	11
1.2.3	Radar	12
1.2.4	Choix de capteurs pour les systèmes de perception	14
1.3	Contributions et organisation du manuscrit	15
1.3.1	Objectifs	15
1.3.2	Contributions	15
1.3.2.1	Une architecture de fusion modulaire sans a priori applicatif basée sur des capteurs intelligents	16
1.3.2.2	La gestion explicite des problèmes d’occultation avec une ca- méra	16
1.3.2.3	La gestion de la corrélation de détection associé aux capteurs	16

TABLE DES MATIÈRES

1.3.2.4	La mise en place une méthode d'évaluation de performance de capteur intelligents	16
1.3.2.5	La validation sur des séquences réelles	17
1.3.2.6	Liste des publications	17
1.3.3	Organisation du manuscrit	17
2	État de l'art : fusion de données	19
2.1	Introduction	20
2.2	Approches de fusion de données	21
2.2.1	Fusion de données	21
2.2.1.1	Définition générale	21
2.2.1.2	Rôle de la fusion	22
2.2.1.3	Notions importantes	22
2.2.2	Différentes architectures de fusion	23
2.2.2.1	Aspect temporel	24
2.2.2.2	Aspect spatial	24
2.2.3	Différents niveaux de fusion	26
2.2.4	Application	27
2.3	Approches pour le traitement de l'information	29
2.3.1	Notations	29
2.3.2	Introduction	29
2.3.3	La théorie des probabilités	29
2.3.3.1	Notations	29
2.3.3.2	Introduction	30
2.3.3.3	Généralités	30
2.3.3.4	Modélisation	33
2.3.3.5	Estimation	33
2.3.3.6	Combinaison	35
2.3.3.7	Décision	36
2.3.3.8	Limites et intérêts	37
2.3.4	La théorie des croyances	38
2.3.4.1	Notations	38
2.3.4.2	Introduction	38
2.3.4.3	Modélisation	38
2.3.4.4	Estimation du modèle	41

TABLE DES MATIÈRES

2.3.4.5	Combinaison	41
2.3.4.6	Décision	43
2.3.4.7	Limites et Intérêts	44
2.3.5	La théorie des possibilités	44
2.3.5.1	Notations	44
2.3.5.2	Introduction	44
2.3.5.3	Généralités	44
2.3.5.4	Estimation du modèle	47
2.3.5.5	Combinaison	47
2.3.5.6	Décision	50
2.3.5.7	Limites et intérêts	50
2.3.6	Comparaison	50
3	État de l'art : Pistage multi-cibles	53
3.1	Notations	54
3.2	Problème d'estimation	54
3.2.1	Notations	54
3.2.2	Introduction	55
3.3	Problématique du pistage multi-cibles	58
3.3.1	Introduction	58
3.3.2	Différentes approches	59
3.4	Méthode du plus proche voisin	60
3.4.1	Filtrage de Kalman	60
3.4.2	Associations mesures/cibles	61
3.4.3	Fenêtrage statistique	62
3.5	Probabilistic Data Association (PDA)	63
3.5.1	Notations	63
3.5.2	Description du PDA	63
3.6	Joint Probabilistic Data Association (JPDA)	65
3.7	Multiple Hypothesis Tracker (MHT)	67
3.7.1	Notations	67
3.7.2	Description du MHT	67
3.7.3	TOMHT	68
3.7.3.1	Formation et gestion des pistes	68
3.7.3.2	Clustering	69

TABLE DES MATIÈRES

3.7.3.3	Formation des hypothèses	70
3.7.3.4	Évaluation globale d'une piste	70
3.7.3.5	Estimation et merging	70
3.8	Probability Hypothesis Density (PHD)	72
3.8.1	Notations	72
3.8.2	Ensemble Fini Aléatoire	72
3.8.3	Équations du filtre	73
3.9	Cardinalized Probability Hypothesis Density (CPHD)	75
3.9.1	Notations	75
3.9.2	Description du CPHD	75
3.10	Implémentations possibles des filtres PHD et CPHD	78
3.11	Gaussian Mixture Cardinalized Probability Hypothesis Density (GMCPHD)	79
3.11.1	Notations	79
3.11.2	Introduction	79
3.11.3	Prédiction	80
3.11.4	Naissance des cibles	81
3.11.5	Mise à jour	81
3.11.6	Probabilité de détection variable	83
3.11.7	Réduction du nombre de gaussiennes	85
3.11.8	Évaluation du nombre de cibles	86
3.11.9	Fonction élémentaire symétrique	86
3.11.9.1	Exemple	86
3.11.9.2	Forme récursive	87
3.12	Comparaison de filtres	89
4	Pistage de cibles en contexte autoroutier	91
4.1	Notations	92
4.2	Introduction	93
4.3	Architecture de fusion proposée	94
4.3.1	Fusion modulaire	94
4.3.2	Pistage Multi-cibles Multi-capteurs (MSMTT)	94
4.3.3	Capteurs asynchrones	94
4.4	Choix du filtre de pistage	96
4.4.1	Situation sur autoroute	97
4.4.2	Situation sur route	100

TABLE DES MATIÈRES

4.4.3	Choix	100
4.5	L'apport de la classification au filtre	103
4.6	Paramétrage du filtre	107
4.6.1	Paramètres applicatifs	107
4.6.2	Paramètres d'implémentation	109
4.6.3	Paramètres de capteur	109
4.6.4	Vérité terrain	110
4.6.5	Définition des paramètres	113
4.6.5.1	Identification du bruit de capteur	113
4.6.5.2	Identification de la probabilité de détection	114
4.7	Problématique d'occultation	118
4.7.1	Définition du problème	118
4.7.2	Gestion des occultations propre au système de détection	118
4.7.3	Gestion des occultations par le système de pistage	120
4.7.4	Probabilité de détection et occultations	121
4.7.4.1	Largeur des cibles	122
4.7.4.2	Marginale de $f_G(x, y)$	126
4.8	Problématique de corrélation de données	129
4.8.1	Définition du problème	129
4.8.2	Corrélation de probabilité	130
4.8.3	Implémentation	131
4.8.3.1	Définition du paramètre α	131
4.8.3.2	Définition du paramètre β	132
4.8.3.3	Étape de Prédiction	132
5	Résultats	135
5.1	Introduction	136
5.2	Véhicule expérimental	137
5.3	Paramètres capteurs du filtre	138
5.3.1	Bruit affectant l'estimation de position	138
5.3.2	Probabilité de détection	139
5.4	Apport de la classification au filtre	141
5.5	Apport des occultations	144
5.5.1	Occultation Piéton/Voiture	144
5.5.2	Occultations Voiture/Voiture	149

TABLE DES MATIÈRES

5.5.3	Comparaison avec occultation binaire	153
5.6	Apport de prise en compte de la corrélation des données capteurs	158
5.6.1	Exemple de situation contrôlée	158
5.6.2	Exemple sur un cas d’occultation	158
5.7	Résultats quantitatifs du filtre global	161
5.7.1	Exemple de situation réelle	161
5.7.2	Comparaison vérité terrain	161
6	Conclusion générale et perspective	165
6.1	Conclusion	166
6.2	Perspectives	168
6.2.1	Amélioration de la prédiction d’état	168
6.2.2	Fusion caméra radar GPS	169

Table des figures

1.1	Architecture classique pour les ADAS	3
1.2	Différents champs de vue des capteurs ADAS.	4
1.3	Diagramme fonction de véhicule autonome (voir [28])	6
1.4	Schéma et exemple de fonctionnement d'un lidar.	7
1.5	Image des impacts lidar à 4 nappes.	8
1.6	Exemple de résultats de scanner lidar à 64 nappes	9
1.7	Modèle géométrique de prise de vue	10
1.8	Diagramme schématique de la géométrie image	10
2.1	Différents choix de synchronisation	25
2.2	architecture spatiale : F= nœud de fusion, S= Source de données, C=Consommateur d'information	26
2.3	Différentes niveaux d'abstraction de d'information pour la fusion	27
2.4	Loi des probabilités totales	32
2.5	Théorème de Bayes	32
3.1	Problème d'estimation	55
3.2	Exemple de scénario problématique d'association mesures/cible	58
3.3	Arbre représentant l'ensemble des associations possibles	68
4.1	Image webcam de la situation : 4 voitures sont détectées	97
4.2	Résultats des filtres pour la situation de la Figure 4.1.	98
4.3	Mesures et résultats des filtres concernant la voiture 1 de la Figure 4.2.	99
4.4	Estimation du nombre de cibles.	99
4.5	Image webcam d'une situation basse vitesse : le passage à un rond point	100
4.6	Mesures et résultats des filtres pour la situation de la Figure 4.5.	101
4.7	Estimation du nombre de cibles de la situation de la Figure 4.5.	102
4.8	Véhicule d'essai utilisé.	108

TABLE DES FIGURES

4.9	Exemple d'image représentant la vérité terrain.	111
4.10	Erreur de position longitudinale (Caméra).	114
4.11	Relation entre la position longitudinale et l'écart type de l'erreur de la position longitudinale des cibles pour la Caméra.	115
4.12	Probabilité de détection (Radar).	115
4.13	Relation entre l'angle formé par la cible et l'axe longitudinale et la probabilité de détection pour le Radar.	116
4.14	Exemple d'une situation d'occultation	119
4.15	Exemple d'une situation d'occultation	119
4.16	La marginale f_G^r	123
4.17	Schéma pour la largeur.	124
4.18	Simulation de la probabilité d'occultation.	126
4.19	Simulation de la probabilité d'occultation.	126
4.20	Exemple de construction de la carte $Po_1(x, y)$	128
4.21	Définition de α	131
4.22	Exemple de l'évolution de la probabilité de détection pour différentes valeurs de β	132
5.1	Véhicule utilisé pour les tests	136
5.2	Exemple d'une situation normale de conduite, vue par la webcam	138
5.3	Estimation du nombre de cibles par le filtre GMCPHD avec différents champs de vue Radar	139
5.4	Image webcam de la situation : 3 voitures sont détectées	141
5.5	Probabilité de type de cible.	142
5.6	Résultats du filtre avec gestion des occultations pour la situation décrite sur la Figure 4.14.	144
5.7	Exemple d'une situation d'occultation	145
5.8	Résultats du filtre avec gestion des occultations pour la situation décrite sur la Figure 4.14.	146
5.9	Résultats du filtre sans gestion des occultations pour la situation décrite sur la Figure 4.14.	147
5.10	Image Webcam : exemple de situation d'occultation.	147
5.11	Résultats du filtre avec gestion des occultations pour la situation décrite sur la Figure 5.10.	148

TABLE DES FIGURES

5.12 Image webcam de la situation : 2 voitures sont détectées, une voiture change de voie	149
5.13 Résultats du filtre avec ou sans gestion des occultations pour la situation décrite dans la Figure 5.12.	150
5.14 Résultats du filtre avec et sans gestion des occultations pour la situation décrite dans la Figure 5.12.	152
5.15 Image Webcam : exemple de situation d’occultation.	153
5.16 Estimation de la probabilité de détection de chaque piste.	154
5.17 Estimation du nombre de cibles par le filtre : les croix noires correspondent aux détections de la caméra (pour cette situation le Radar ne détecte aucune cible), les résultats du filtre sans gestion d’occultation sont représentés en rouge, les résultats du filtre avec une gestion binaire des occultations en bleu, les résultats du filtre avec gestion gaussienne des occultations en verts. . . .	155
5.18 Birdview de la situation décrite sur la Figure 5.15.	155
5.19 Visualisation d’une carte d’occultation avec une gestion binaire.	156
5.20 Image Web-cam : 5 piétons sont détectés par la Caméra.	158
5.21 Estimation du nombre de cibles.	159
5.22 Résultats du filtre avec gestion de la corrélation pour la situation présentée sur la Figure 5.15	160
5.23 Exemples de résultats.	162
5.24 Visualisation du temps moyen	164

Liste des tableaux

2.1	Notations générales utilisées pour les théories de fusion	29
2.2	Notations utilisées pour la théorie des probabilités	30
2.3	Exemple de notation pour représenter les probabilités	34
2.4	Vraisemblance de l'exemple.	34
2.5	Exemple de calcul de la probabilité qu'il y ait une cible ou non en fonction des mesures des deux sources	36
2.6	Notations utilisées pour la théorie de l'évidence	38
2.7	Exemple d'attribution des masses de la fusion conjonctive	43
2.8	Notations utilisées pour les ensembles flous et la théorie des possibilité	44
2.9	Avantages et inconvénients des différentes théories.	51
3.1	Notations générales utilisées dans ce Chapitre	54
3.2	Notations utilisées pour les problème d'estimation	54
3.3	Notations utilisées pour la méthode du PDA, JPDA	63
3.4	Notations utilisées pour la méthode du MHT	67
3.5	Notations générales utilisées pour les filtres basé sur des RFS, le PHD et le CPHD	72
3.6	Notations supplémentaires utilisées pour le CPHD	75
3.7	Notations utilisées pour le GMCPHD	79
4.1	Notations utilisées pour le GMCPHD	92
4.2	Ecart type de l'erreur de position entre le résultat du filtre et la référence de position du capteur Lidar.	96
4.3	Tableau comparatif des filtres TOMHT et GMCPHD	100
5.1	Moyenne de la distance quadratique entre la position estimée et la position de l'objet de vérité terrain en deux dimensions (latérale et longitudinale) . .	163

5.2	Performances de détection du système de fusion comparé aux détections des capteurs (nombre de fausses alarmes et taux de détection sont analysés).	. . . 163
-----	--	-----------

Chapitre 1

Introduction et analyse de la problématique

Sommaire

1.1	Objectifs: applications ADAS	2
1.2	Capteurs ADAS	7
1.3	Contributions et organisation du manuscrit	15

1.1 Objectifs : applications ADAS

Nous introduisons dans cette section le cadre du travail décrit dans ce mémoire. Ce travail est destiné à être utilisé dans des systèmes d'aide à la conduite. Ces systèmes, communément appelé ADAS de l'anglais *Advanced Driver Assysted System* sont des systèmes allégeant et facilitant la tâche du conducteur. Ils peuvent empêcher l'apparition d'une situation provoquant un accident, ou encore faciliter la vie à bord du conducteur, lui permettant ainsi de garder sa vigilance intacte, ou encore d'améliorer sa perception de l'environnement.

Nous verrons donc tout d'abord les différents objectifs applicatifs de ce travail, ainsi que les entrées et sorties du système créé.

1.1.1 Architecture classique de systèmes d'aide à la conduite

Les systèmes d'aide à la conduite peuvent généralement se décomposer en plusieurs tâches : un module de perception, de fusion, de décision, et d'action (voir Figure 1.1). Nous développons dans la suite chacun des différents modules.

1.1.1.1 Perception

Le module de perception a pour but d'obtenir des informations sur l'état d'un système.

Dans les systèmes d'aide à la conduite, ces informations peuvent provenir :

- de capteurs proprioceptifs, qui fournissent des informations concernant l'état du véhicule, telles que sa vitesse, l'angle au volant,...,
- de capteurs extéroceptifs, qui fournissent des informations concernant l'environnement du véhicule, les positions des piétons ou voitures proches,...,
- de communications V2V (vehicle to vehicle) [32], qui permettent l'échange d'informations avec un autre véhicule, ou encore une infrastructure,
- de bases de données, qui fournissent des informations contextuelles, telles que des cartes.

Ces informations sont ensuite exploitées pour fournir au reste du système les informations utiles spécifiques à l'application visée. Par exemple, dans le cas d'un capteur utilisé dans le cadre d'une application de détection de voiture : les voitures sont détectées dans l'image caméra, et les attributs de détection sont envoyés à l'étape suivante.

1.1.1.2 Fusion

Dans les cas où plusieurs sources d'informations sont utilisées (fusion multi sources), ou dans le cas où une seule source est utilisée sur un intervalle de temps (fusion temporelle),

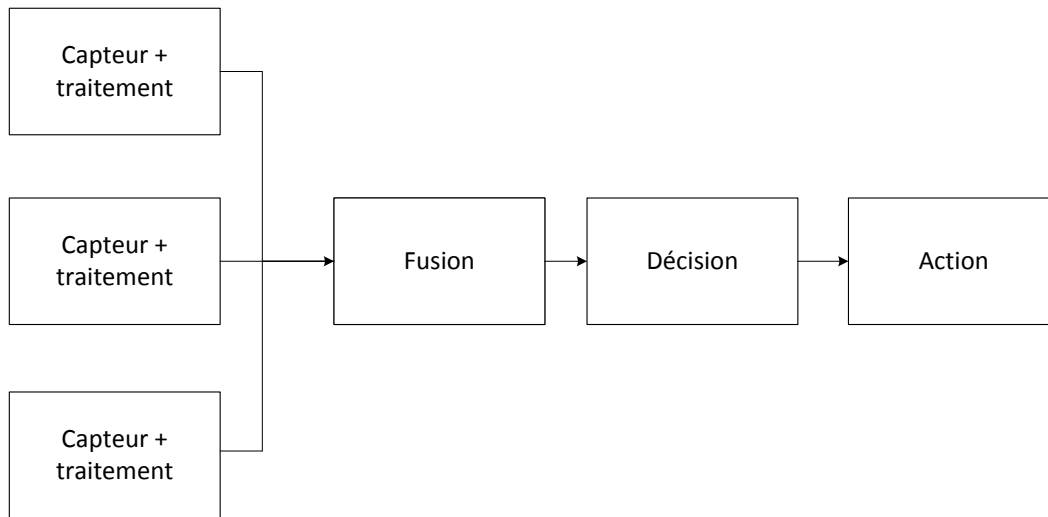


FIGURE 1.1 – Architecture classique pour les ADAS

une étape dite *de fusion* est effectuée pour améliorer l'information traitée et transmise par le module du capteur.

La sortie de ce sous-système dépend de l'application. Cette étape est le cœur de notre travail, elle sera développée dans la section 2.2.

1.1.1.3 Décision

A partir de l'information synthétisée des informations capteurs (la sortie de l'étape de fusion), des décisions sont prises afin d'aboutir à une action précise. Par exemple, dans les applications de suivi de véhicule (voir paragraphe 1.1.2.1), cette étape consiste à choisir le véhicule à suivre à partir de la liste des véhicules environnants et de leur position. La position ou la vitesse relative de ce véhicule sont utilisées pour *agir*.

1.1.1.4 Action

Dans les applications ADAS, l'action peut être de deux types :

- soit une interface homme-machine (IHM), l'objectif étant alors d'avertir le conducteur sur une situation particulière. La difficulté est de transmettre les informations nécessaires sans pour autant distraire le conducteur. Il y a alors un travail important d'ergonomie pour que l'IHM soit efficace et utilisée,
- soit une action directe sur le contrôle du véhicule. Ces actions peuvent aller d'une




FIGURE 1.2 – 1 correspondent aux champs de vue des capteurs ultrasons, 2 est le champ de vue lidar, 3 est le champ de vue camera, 4 est la champ de vue radar

simple limite d'accélération (tel que le limiteur), au contrôle directionnel de la voiture, en passant par le freinage automatique.

1.1.2 Applications ADAS

Nous nous intéressons dans ce mémoire aux applications de conduite frontale (contrairement aux applications de manœuvre, telle que le parking automatique), c'est à dire des systèmes d'aide à la conduite basés sur la perception frontale au véhicule (les capteurs 2,3,4 de la Figure 1.2).

1.1.2.1 ACC, DW

Les systèmes DW pour *Distance warning* ou ACC pour *Automatic Cruise Control* sont des exemples typiques d'applications frontales d'aide à la conduite. Ces deux applications sont rassemblées dans ce paragraphe car elles sont basées toutes les deux sur la détection et la localisation de la ou les voitures que notre véhicule suit. A partir de la localisation de la

voiture à suivre, l'application DW va avertir le conducteur lorsqu'il sera trop proche de celle-ci, alors que l'ACC permet d'adapter la vitesse de notre véhicule en fonction du comportement du véhicule suivi.

Le ou les capteurs utilisés peuvent comprendre une caméra [102], un radar [105], ou encore un lidar [10]. L'étape de décision consiste à choisir la cible utile pour ses applications, c'est à dire la cible devant nous et dans la même voie de circulation que nous. La gestion de l'action est différente entre les applications de DW et d'ACC, l'application DW est un message envoyé au conducteur, alors que l'ACC va agir directement sur le véhicule.

Beaucoup de travaux ont été effectués concernant ces applications, certains d'entre eux sont répertoriés dans [109].

1.1.2.2 Pré-crash piéton

Nous pouvons aussi parler de toute une catégorie d'applications frontales du véhicule, celle concernant la protection des piétons. Les piétons sont les usagers de la route les plus vulnérables, c'est pour cela que toute une gamme d'ADAS est destinée à diminuer la fréquence des accidents entre un véhicule et un piéton ou alors d'en diminuer les conséquences. Pour cela il faut pouvoir détecter et estimer la position des piétons en temps réel. Ce genre de système existe basé sur des caméras et/ou des lidars [79] ou encore et/ou des caméras infrarouges [75].

Cet énumération d'applications n'est pas exhaustive, elle cite seulement les deux types d'applications les plus couramment étudiés, celles concernant la ou les voitures suivies et celles concernant la détection des piétons. D'autres applications peuvent être aussi imaginées utilisant une carte de localisation des entités frontales à notre véhicule dans certains cas particuliers. Pour ne citer qu'eux, nous pouvons parler des applications d'aide à la conduite aux abords d'une intersection, ou spécifiques à la détection de nuit.

1.1.2.3 Véhicule autonome

Venue de la science fiction, l'idée d'une voiture à conduite autonome est de plus en plus réaliste [28]. Cette idée est très attractive car son potentiel est immense. Une voiture autonome, c'est à dire qui peut aller d'un point A à un point B sans intervention humaine, permettrait entre autre d'améliorer la sécurité routière, la productivité et la consommation d'essence. La voiture serait un système plus sûr grâce à la réduction du nombre d'accidents causés par les conducteurs. Concernant l'augmentation de la productivité cela proviendrait du fait que de plus en plus de temps est consacré au transport, et avec les voitures auto-

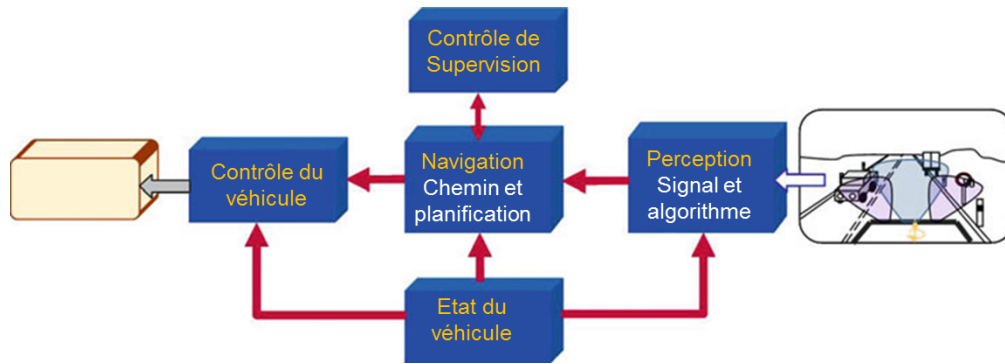


FIGURE 1.3 – Diagramme fonction de véhicule autonome (voir [28])

nommes, ce temps retrouvé pourrait être réutilisé pour travailler ou se reposer. La diminution de la consommation d'essence serait possible grâce à la prévision en temps réel de la conduite la plus optimale. De plus, la distance inter-véhicule sera diminuée (les véhicules étant plus sûrs), ainsi la résistance de l'air sera réduite. Un grand nombre de recherches sont effectuées concernant l'autonomie des systèmes de transport, de même un grand nombre de projets de recherche sont consacrés à ce domaine, pour en citer quelque uns, nous pouvons parler du projet SAFESPOT[76], PReVENT [83], HAVEit [73], interactIVe...

La perception de l'environnement est nécessaire pour permettre une conduite automatique (voir Figure 1.3). Dans ce cadre, notre travail de fusion de capteurs de perception pourrait être très utile.

Nous venons d'introduire le cadre de notre travail ainsi que quelques applications possibles.

Dans la suite, nous cherchons à créer une carte d'environnement compatible avec l'ensemble des applications considérées ci-dessus. Cette création devra se faire en temps réel et décrire l'état de l'ensemble des entités routières frontales à notre véhicule (voitures, piétons...). Nous allons dans la section suivant introduire les capteurs classiquement utilisés dans le cadre de ces systèmes d'aide à la conduite.

1.2 Capteurs ADAS

Nous nous intéressons dans ce mémoire uniquement aux capteurs permettant la détection et la localisation d'obstacles. Seuls certains capteurs sont couramment utilisés dans le cadre des systèmes d'aide à la conduite. Dans l'industrie, les capteurs utilisés sont des capteurs intelligents, c'est à dire des modules de capteurs avec leur propre traitement des données. Les données brutes de ces capteurs sont pré-traitées, ce qui en fait des capteurs intelligents. Nous décrirons dans la suite les principales technologies de capteurs. Nous verrons aussi les différents systèmes de traitement des données brutes de capteurs permettant l'estimation d'information sur chacune des cibles détectées. Nous parlerons ainsi de capteurs optiques tels que le LIDAR, et la CAMERA, ou encore le RADAR.

1.2.1 Lidar, ou télémètre laser




FIGURE 1.4 – Le schéma du dessus correspond à une représentation du système physique du lidar. L'image du milieu représente une scène observée. La dernière image correspond aux impacts lidar après observation de la scène supérieure.

Un capteur Lidar, acronyme de l'expression en langue anglaise «*light detection and ranging*», est une technologie de mesure optique basée sur l'analyse des propriétés d'un faisceau renvoyé vers son émetteur.

La distance à un objet ou à une surface est donnée par la mesure du délai entre l'impulsion et la détection du signal réfléchi. Le lidar balaie son champ de vision avec son faisceau laser et mesure pour chaque point de l'espace balayé la distance entre le lidar et le point, permettant




FIGURE 1.5 – Exemple d’une scène routière. Les différentes couleurs de points correspondent aux différentes nappes. Le cadre rouge entoure les impacts liés à un camion.

la reconstruction d’un modèle tridimensionnel de la scène (voir Figure 1.4). De nos jours, ce type de capteur a évolué vers des capteurs avec un champ de vision, *Field Of View* (FOV) vertical plus important, et cela passe par une multiplication du nombre de faisceaux. On peut voir sur les figures 1.5 et 1.6 des exemples de résultats de lidar à 4 ou à 64 nappes. Un capteur lidar renvoie tout un ensemble de points 3D, qui correspondent à l’ensemble des impacts. La difficulté avec un capteur lidar est de savoir si un point détecté par le lidar appartient à une cible ou à l’environnement (voir l’exemple des figures 1.5 et 1.6).

Les capteurs Lidar sont largement utilisés pour la robotique intérieure et extérieure.

Le principal avantage du Lidar est lié à la précision de distance de chaque impact, l’inconvénient en contrepartie est lié à la difficulté de l’interprétation des données reçues. De même, ce capteur ne fournit des informations que sur le premier impact. De plus, le lidar est un capteur coûteux pour l’instant pour être installé dans des voitures particulières de coût moyen. Ces capteurs ont aussi le défaut de ne pas fonctionner parfaitement avec des conditions météorologiques dégradées. Un autre défaut de ce capteur est lié au système physique définissant ce capteur, la présence de pièce en mouvement le rend difficile à implanter dans la voiture.




FIGURE 1.6 – Exemple de résultats de scanner lidar à 64 nappes

1.2.2 Caméra

Les capteurs caméra sont de plus en plus utilisés dans les systèmes d'aide à la conduite. Cet usage est dû principalement au coût modéré de ces capteurs, à la richesse d'information fournie par une caméra et à la familiarité des données. En effet, en tant qu'humain, nous avons l'habitude d'analyser notre environnement principalement avec nos yeux, une caméra est le capteur se rapprochant le plus de notre vision naturelle. Avec les systèmes pré-traitant la vidéo d'une caméra, on peut distinguer principalement deux tâches. Tout d'abord, une étape de détection, suivie par une étape d'estimation de paramètres concernant la détection de cible. L'étape d'estimation d'information telle que la distance ou la vitesse est différente entre les systèmes mono-caméra et stéréo-vision.

Il existe dans la littérature une pléthore de différents systèmes de détection de cibles dans les images caméra. Ces systèmes de détection peuvent se baser sur des techniques de soustraction de fond [40, 74]. Malheureusement, ce genre de techniques est très sensible au changement d'intensité dans l'image. Des méthodes d'apprentissage basées sur des caractéristiques de détection sont plus robustes. Il existe aussi des méthodes telles que le *boosting* ([124]) ou la méthode de SVM (*support vector machine* [14]). Après l'étape de détection de la cible dans l'image, nous cherchons à en déduire des informations concernant l'état de cette cible.

1.2.2.1 Systèmes Mono-caméra

La relation entre un point d'image et un objet dans le monde réel peut être définie par le modèle sténopé d'une caméra (voir Figure 1.7). Dans le cas de systèmes de perception basés sur une seule caméra, l'estimation de la position des cibles détectées peut se faire grâce à la méthode développée dans [102]. L'hypothèse d'un monde plan est effectuée (on se trouve alors dans le cas présenté Figure 1.8), la distance est alors calculée par :

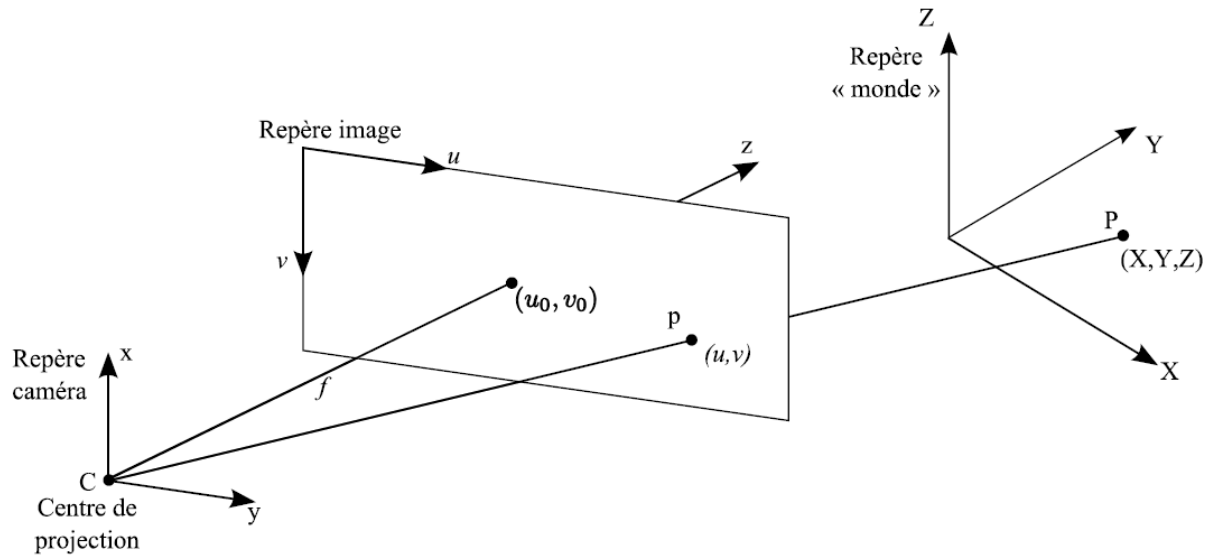


FIGURE 1.7 – Modèle géométrique de prise de vue




FIGURE 1.8 – Diagramme schématique de la géométrie image

$$Z = \frac{fH}{y}$$

y est la hauteur de l'image de la cible, f est la focale de la caméra, H est la hauteur réelle de la cible, et Z la distance entre la caméra et la cible.

Lorsque l'hypothèse de monde plane n'est pas vérifiée, les calculs sont alors modifiés grâce aux méthodes présentées dans [101, 45]. Tout d'abord, l'angle de montage de la caméra et l'angle de tangage sont estimés par la méthode présentée dans [101]. Ensuite pour compenser l'erreur sur la planéité du monde, une analyse des lignes de marquages au sol est effectuée[45].

A partir d'une unique séquence vidéo, une estimation de la vitesse peut aussi être faite en dérivant la distance des objets ou encore être faite par une mesure du flot optique. La première méthode n'est pas conseillée, car elle consiste à soustraire deux estimations bruitées (voir [102] pour plus d'explications). Ce n'est pas le cas pour la deuxième méthode qui utilise la largeur des véhicules détectés. Le flot optique est utilisé pour détecter la largeur image des cibles $w_{1,2}$. La largeur réelle W peut être calculée à partir des largeurs images $w_{1,2}$.

$$W = \frac{w_{1,2}Z_{1,2}}{f}$$

On a alors le calcul de la vitesse :

$$v = \frac{\Delta Z}{\Delta t} = \frac{\frac{fH}{Z_2} - \frac{fH}{Z_1}}{\Delta t} = \frac{fH \frac{w_1 - w_2}{w_1 w_2}}{\Delta t} = \frac{Z_1 \frac{w_1 - w_2}{w_2}}{\Delta t}$$

Les systèmes mono-caméra sont de plus en plus utilisés. Cependant il faut savoir que la précision d'estimation de l'état des cibles est souvent plus erronée qu'avec les systèmes Lidar ou de stéréo-vision.

1.2.2.2 Stéréo-vision

Le procédé de la stéréoscopie est calqué sur la perception humaine du relief grâce à deux images planes que l'on perçoit de chaque œil. Pour plus de détails sur les méthodes de reconstruction 3D à partir d'images, voir le livre[16].

Pour les systèmes de stéréo vision, la première tâche consiste en l'appariement des points représentant le même point réel sur les deux images caméra. Nous expliquons dans la suite le principe de reconstruction stéréo, c'est à dire, le calcul de la position réelle du point à partir des coordonnées image des points appariés (les coordonnées des points dans le repère image de chaque image) en utilisant une modélisation des caméras par un modèle sténopé

(voir Figure 1.7). Notons (X, Y, Z) les coordonnées du point dans l'espace réel, (x, y, z) les coordonnées du point réel dans l'espace caméra, (u, v) (resp. (u', v')) les coordonnées du point dans l'image 1 (resp. 2), la Figure 1.7 représente la représentation pour une des deux caméra. Pour chaque image, nous pouvons exprimer les coordonnées image d'un point (u, v) à partir des coordonnées réel du point correspondant (X, Y, Z) .

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = R \times \begin{pmatrix} x \\ y \\ z \end{pmatrix} + t$$

$$\begin{pmatrix} Z \times u \\ Z \times v \\ Z \end{pmatrix} = \begin{pmatrix} k_x f & 0 & u_0 \\ 0 & k_y f & v_0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

R et t correspondent aux matrices de rotation et de translation permettant de passer du repère caméra au repère réel. k_x et k_y sont des constantes utilisées pour prendre en compte la non isotropie des caméra, f est la focale de la camera, les autres variable sont définies dans la figure 1.7.

Ainsi la distance des points réels, encore nommée disparité, peut être calculée à partir des coordonnées images des deux images.

La position relative des cibles aux caméras est précise (l'erreur peut être centimétrique), c'est pourquoi un nombre important de systèmes d'aide à la conduite utilisent des systèmes de stéréo vision dans la littérature [44, 42, 66, 110] .

Cependant ces systèmes sont difficiles à utiliser dans l'industrie car la précision d'estimation de position des cibles détectées dépend de la précision d'installation des deux caméras dans la voiture. La maintenance des systèmes de stéréo-vision est aussi difficile, le moindre changement de position d'une des deux caméras provoque des problèmes d'estimation. Cela explique l'augmentation de travaux concernant l'utilisation de système mono-caméra [53, 122], mais aussi le nombre (deux fois plus faible) de capteurs à utiliser (ce qui entraine logiquement une diminution du prix du système de capteur).

1.2.3 Radar

Le RADAR, acronyme anglais pour *Radio Detection And Ranging* est un système basé sur la propagation des ondes électromagnétiques, plus exactement sur celles des ondes radio-fréquence (RF). Un radar émet de puissantes ondes, produites par un oscillateur et transmises

par une antenne. En analysant le signal réfléchi, il est possible de localiser et d'identifier l'objet responsable de la réflexion, ainsi que de calculer sa vitesse de déplacement grâce à l'effet Doppler.

Si l'on considère la forme d'onde, les radars peuvent être de deux types : à ondes continues (CW pour *Continuous Wave*) ou à ondes pulsées (PR pour *Pulsed Radars*) [112]. Il est à noter que ces radars peuvent mesurer à la fois vitesse et distance en utilisant des lois de modulation adaptées.

Les radars PR envoient une impulsion alors que les radars CW émettent sans interruption une énergie électromagnétique. Les radars CW non-modulés peuvent déterminer de façon fiable la vitesse radiale des cibles (Doppler) ainsi que leur position angulaire. Néanmoins, l'information de distance ne peut pas être extraite sans utiliser une forme quelconque de modulation. Les radars à onde continue FMCW (*Frequency Modulated Continuous-wave*) émettent sans interruption un signal modulé en fréquence. L'écho est donc reçu et traité continuellement. La forme d'onde est considérée comme une sinusoïde pure avec une fréquence modulée autour d'une valeur centrale f_0 . Les spectres des échos radar issus de cibles fixes seront donc concentrés autour de la fréquence f_0 . La fréquence centrale des réponses d'objets mobiles sera décalée de la fréquence Doppler f_d . La fréquence Doppler est ensuite utilisée pour en déduire la vitesse radiale des cibles mobiles. Le problème est alors que l'estimation de la distance des cibles est liée à l'estimation de la vitesse des cibles, les erreurs d'estimation des deux valeurs sont liées.

Contrairement aux capteurs utilisant les longueurs d'onde du spectre visible, les ondes du radar ont une longueur d'onde suffisamment grande pour diminuer l'impact des particules présentes dans l'atmosphère. C'est pour cela que les radars sont moins sensibles aux conditions atmosphériques que les capteurs optiques. De même, l'estimation de distance et de vitesse relative des cibles mobiles est souvent très précise. De plus, contrairement aux capteurs optiques, l'utilisation d'un signal continu et permissif par le radar, le rend capable de détecter des objets occultés, le signal n'étant pas arrêté par la première cible détectée. C'est cette précision et cette stabilité de détection qui a encouragé l'utilisation des radars pour la perception de l'environnement automobile. De plus contrairement aux systèmes rotatifs, tels que le Lidar, l'absence de mouvement mécanique rend moins compliqué la maintenance du véhicule (cet argument tient aussi pour les systèmes Caméra).

Par exemple, pour le Darpa challenge, l'équipe de Stanford [104] à utilisé deux radars 24 GHz et l'équipe de Cambridge [51] à utilisé 15 radars pour le suivi de véhicule à grande distance. Cependant, les phénomènes d'interférences entre les échos radar peuvent faire apparaître ou disparaître des impacts fantômes, des fausses alarmes. L'estimation de l'azimut

est aussi assez imprécise avec le radar. De plus, le radar reste un capteur dont l'interprétation du signal est complexe en fonctionnement terrestre.

D'autres systèmes de détection existent, bien qu'ils soient en général moins couramment utilisés dans les systèmes industriels. Nous pouvons par exemple citer une nouvelle gamme de caméra, les caméras TOF *Temps de vol (Time Of Flight)*[87, 32]. Ces caméras illuminent la scène observée avec un pulse de lumière et mesure le temps de vol du pulse entre la caméra et l'objet observé. Chaque pixel de l'image mesure indépendamment la distance à l'objet correspondant. Le principe de mesure de distance est similaire à celui utilisé par le Lidar.

1.2.4 Choix de capteurs pour les systèmes de perception

Pour la création de notre carte d'environnement nous avons décidé de nous baser sur un système radar et un système caméra. Ce choix de plus en plus classique dans les systèmes ADAS est motivé par des raisons de coût mais aussi de performance. Comme dit précédemment, les performances du radar sont quasiment indépendantes des conditions climatiques (il fonctionne aussi de jour, de nuit, par temps de brouillard ou de pluie) et il est précis sur l'estimation de vitesse relative et de distance. La caméra, quant à elle, permet une estimation d'état de cible un peu plus erronée mais elle permet d'avoir une grande richesse d'information, des informations contextuelles ou encore de classification des cibles. De plus ces deux capteurs n'ont pas de mouvements physiques, or un système robotique physique (tel que les capteurs rotatifs) peut s'abîmer dans le temps et le comportement peut alors varier.

Dans ce mémoire, nous considérons notre travail comme complètement indépendant du système de perception. Cela signifie que le système de perception est constitué de capteurs industriels intelligents, dont le traitement ou les données brutes sont inaccessibles. Une des difficultés de ce travail est donc de pouvoir utiliser des capteurs dits "boîte noire" de façon efficace. Nous cherchons donc à construire un système de fusion générique capable d'utiliser différents systèmes de perception tant que la sortie du module de perception est identique, c'est à dire une liste de cibles détectées associées à une estimation d'état pour chaque cible.

1.3 Contributions et organisation du manuscrit

1.3.1 Objectifs

Ma thèse étant une thèse CIFRE, Conventions Industrielles de Formation par la Recherche (c'est à dire en collaboration avec l'entreprise Renault et l'institut Pascal), certaines contraintes industrielles ont guidées mon travail. Tout d'abord le choix des différentes technologies de capteurs. Nous avons travaillé avec une mono caméra et un radar pour les raisons évoquées précédemment. Ces capteurs sont des capteurs industriels, intelligents. Ils sont appelés "capteurs boîtes noires" car leur données brutes sont inaccessibles et le traitement des données est inconnu. La sortie de ces capteurs est similaire et correspond à une liste d'objets détectés associés à une estimation de position et vitesse de chacun de ces objets et à une classification de ces objets.

De même il est important que notre système soit fortement modulaire afin de permettre l'ajout, la modification ou la suppression d'un capteur facilement. Il faut aussi que notre système de fusion soit temps réel, c'est-à-dire qu'il nous permettent de suivre la fréquence des capteurs sans prendre du retard.

Nous cherchons donc à effectuer un système de fusion entre la camera et le radar pour les scènes routières. Or les capteurs ne sont pas parfaits, ils sont sensibles à des erreurs de détection, comme les fausses alarmes qui correspondent à des détections du capteur qui ne correspondent à aucun objet réel, ou comme les non détections, qui correspondent à des objets réels qui n'ont pas été détectés par le capteur. Nous pouvons aussi noter que l'estimation de l'état des objets, la position et la vitesse par les capteurs n'est pas parfaite, elle peut être erronée. Nous pouvons parler aussi de quelques difficultés liées directement à l'environnement observé. Il y a un nombre inconnu de différents types d'objets à détecter qui ont un mouvement inconnu.

Pour les applications d'aides à la conduite, les erreurs de détections sont problématiques, elles pourraient entrainer des freinages intempestifs ou des accidents. C'est pour cela que nous avons souhaité axer notre étude sur un système de fusion permettant l'amélioration des performances de détection des capteurs.

1.3.2 Contributions

Disposant d'un radar et d'une caméra, dans le cadre d'applications routières, les contributions de cette thèse sont :

1.3.2.1 Une architecture de fusion modulaire sans a priori applicatif basée sur des capteurs intelligents

Nous avons proposé une architecture modulaire de fusion utilisant des données standards provenant de capteurs intelligents. Ces données sont gérées par le moteur de fusion que nous avons développé et autorisant un traitement asynchrone et temps réel des données. La fusion se fait sans aucun a priori applicatif grâce à la gestion de différents types de cible dans le moteur de fusion. Cette architecture à l'avantage majeur de rester générique, seuls les paramètres du système sont à modifier en cas de changement ou de rajout de capteur.

1.3.2.2 La gestion explicite des problèmes d'occultation avec une caméra

Nous avons proposé une méthode permettant de régler le problème des occultations avec une caméra de manière explicite par une méthode probabiliste. C'est à dire que les occultations sont prédites et donc peuvent être résolues naturellement dans le filtre de pistage utilisé. Cette méthode permet de prendre en compte certaines imperfections des données liées à la caméra, telle que : l'imprécision de position estimée des objets, l'incertitude de détection et aussi l'incertitude d'occultation, c'est à dire l'incertitude de détection d'une cible lorsque celle-ci est partiellement occultée dans l'image caméra.

1.3.2.3 La gestion de la corrélation de détection associé aux capteurs

Les capteurs intelligents peuvent produire des données corrélées, potentiellement dues à un pré-traitement des données effectué par les capteurs intelligents. Nous avons proposé une méthode permettant de gérer cette corrélation vis à vis de la performance de détection des capteurs. Cette méthode permet d'éviter une mauvaise estimation du nombre de cibles due à une sous estimation de la probabilité de détection.

1.3.2.4 La mise en place une méthode d'évaluation de performance de capteur intelligents

Nous avons proposé un logiciel permettant l'évaluation des performances de capteurs intelligents grâce à une construction rapide et exact d'une vérité terrain basée uniquement sur des capteurs embarqués dans un véhicule. Cette méthode permet de définir l'ensemble des paramètres nécessaires au système de fusion présenté. En effet, les techniques de fusion actuelles nécessitent en générale une connaissance du comportement des capteurs, ce qui est souvent une tâche difficile à effectuer. Ce système d'évaluation de performance nous permet de

présenter une méthode complète de fusion modulaire, permettant l'intégration d'un nouveau capteur.

1.3.2.5 La validation sur des séquences réelles

Un véhicule démonstrateur, équipé d'un lidar, d'une caméra et d'un radar a été utilisé pour valider notre approche. Les algorithmes ont été implémentés sur un ordinateur portable de bureau classique. La validation a été faite dans des conditions réelles d'utilisation sur route ouverte en environnement urbain. Nous avons validé chacune des contributions de manière qualitative mais aussi quantitative. Les résultats obtenus sont satisfaisants et confirment la pertinence des choix et de l'approche envisagée.

Les travaux de cette thèse ont donné lieu à 4 publications dans des conférences internationales, et un article de revue est en cours d'évaluation. Un brevet a été déposé à l'INPI.

1.3.2.6 Liste des publications

- L. Lamard, R. Chapuis, et J.P Boyer, “Dealing with occlusions with multi targets tracking algorithms for the real road context”, 2012 IEEE Intelligent Vehicles Symposium (IV 2012).
- L. Lamard, R. Chapuis, et J.P Boyer, “ A comparison of two different tracking algorithms is provided for real application”, 2012 IEEE Intelligent Vehicles Symposium (IV 2012).
- L. Lamard, R. Chapuis, et J.P Boyer, “ CPHD filter addressing occlusions with pedestrians and vehicles tracking”, 2013 IEEE Intelligent Vehicles Symposium (IV 2013).
- L. Lamard, R. Chapuis, et J.P Boyer, “Multi target tracking with CPHD filter based on asynchronous sensors”, 16th International Conference on Information Fusion (FUSION 2013).

1.3.3 Organisation du manuscrit

Les Chapitres 2, 3 et 4 proposent une étude bibliographique sur les processus de fusion. Le premier objectif de ces chapitres est de définir les différentes notions rencontrées dans la littérature. Le second objectif est de présenter les outils mathématiques classiquement utilisés pour réaliser la fusion d'information. Le troisième objectif est de répertorier les principaux filtres de pistage afin de dégager les avantages et inconvénients de chacun.

Le Chapitre 4 se divise en 7 sections décrivant chacune une contribution différente.

Tout d’abord l’architecture choisie de notre système de fusion est présentée et justifiée. Cette architecture est basée principalement sur un filtre de pistage de la littérature. Le fonctionnement et l’implémentation de ce filtre est expliqué en détail. Ce filtre est ensuite généralisé afin d’utiliser des informations de classification supplémentaires concernant les objets détectés. Les différentes contributions évoquées précédemment sont ensuite développées : la méthode d’évaluation de capteur intelligent, la prise en compte des occultations avec une caméra et la prise en compte des corrélations de détection.

Le Chapitre 5 présente l’ensemble des résultats permettant la validation des choix évoqués dans le chapitre précédent. Chaque contribution est validée indépendamment des autres avec des données réelles. Des résultats qualitatifs mais aussi quantitatifs sont aussi présentés concernant le système complet. Ces résultats démontrent la pertinence de ce système mais permettent aussi de trouver ses limites.

Le manuscrit se termine par une conclusion générale et quelques perspectives d’amélioration du système (**Chapitre 6**).

Chapitre 2

État de l’art : fusion de données

Sommaire

2.1	Introduction	20
2.2	Approches de fusion de données	21
2.3	Approches pour le traitement de l’information	29

2.1 Introduction

Généralement, la connaissance d'un environnement ou d'un système provient d'une source d'information. Ces sources d'information peuvent être entachées d'imperfections, c'est pour cela que la combinaison de différentes sources d'information, ou encore la combinaison sur un intervalle de temps des informations provenant d'une même source peut fournir une meilleure information finale. La fusion d'informations ou de données a déjà été utilisée dans le cadre d'une grande variété d'applications : militaires [27, 13, 92], médicales [106, 78], financières, météorologique [38], robotique [8], et encore industrielles [35]. Nous décrirons dans ce chapitre l'ensemble des méthodes permettant de réaliser un système de fusion d'informations. Tout d'abord nous présenterons les différentes définitions ou notions permettant de caractériser les informations. Les architectures classiques de fusion existantes seront ensuite introduites. Dans la suite de la section, les différents outils théoriques permettant la définition d'un système de fusion seront décrits : la théorie probabiliste, la théorie de croyance et la théorie des possibilités.

2.2 Approches de fusion de données

2.2.1 Fusion de données

Il faut d'abord savoir, qu'il existe une différence entre fusion de données et fusion de capteurs. Nous parlons dans cette sous-section de fusion de données et non plus de fusion de capteurs car les méthodes et théories présentées correspondent au cadre plus large de la fusion de données et peuvent donc aussi être utilisées dans le cadre de notre travail de thèse, la fusion de capteurs. Nous nous éloignons donc de l'aspect applicatif du sujet de thèse pour nous concentrer sur les techniques existantes de fusion de données.

2.2.1.1 Définition générale

Dans la littérature, il existe une pléthore de définitions de la fusion de données. En effet, bien que le concept de fusion de données soit facile à appréhender, sa définition exacte varie souvent en fonction de l'utilisation ou de l'utilisateur [120].

La définition choisie dans la suite correspond à [119] :

“la fusion de données constitue un cadre formel dans lequel s'expriment les moyens et les techniques permettant l'alliance des données provenant de sources diverses. Elle vise à l'obtention d'information de plus grande qualité ; la définition exacte “de plus grande qualité” dépendra de l'application”.

En général, la fusion est une tâche complexe, qui peut se décomposer en quatre étapes : la modélisation, l'estimation, la combinaison et la décision. Ces différentes étapes serviront de guide dans le paragraphe 2.3 pour expliquer les différents outils théoriques existants dans le cadre de la fusion.

L'étape de la modélisation correspond au choix du formalisme (par exemple, le choix de mesure représentée par des distributions de probabilités). La plupart des modélisations nécessitent une étape d'estimation de modèle (par exemple, l'estimation de probabilité par apprentissage). Dans cette section, lorsque l'on parle d'étape “d'estimation”, cela signifie “estimation du modèle du système de fusion de donnée”. L'utilisation du mot “estimation” évoluera dans la section 3 consacré à l'estimation de l'état d'un système.

L'étape de combinaison est définie par un opérateur préalablement choisi afin de fusionner au mieux les différentes données (par exemple, la règle de Bayes). L'étape finale de la fusion de donnée correspond à l'étape de décision. A partir du résultat de la combinaison, une décision finale est choisie (grâce au maximum de vraisemblance par exemple).

2.2.1.2 Rôle de la fusion

La fusion de données permet de combiner soit des informations provenant de sources différentes, soit des informations d'une source unique sur un intervalle de temps. L'objectif est d'obtenir, soit une meilleure compréhension de la scène comparée aux informations initiales, soit une aide pour l'accomplissement d'une mission. Wald dans [121] distingue deux préoccupations chez les utilisateurs de fusion de données :

- la reconstruction d'un environnement, d'un état, d'un système. Dans le domaine des véhicules intelligents, l'apport de la fusion peut se trouver par exemple dans l'amélioration de la précision de localisation ou dans l'amélioration des capacités de détection d'obstacles.
- la prise de décision. La fusion de données peut par exemple améliorer un résultat de classification ou de diagnostic. La fusion permet ainsi de raffiner la qualité de la décision.

2.2.1.3 Notions importantes

L'intérêt premier d'un système de fusion est de pouvoir améliorer les informations initiales en les combinant. Cette amélioration est possible car les informations initiales ne sont pas parfaites. Ces imperfections sont importantes, leur connaissance nous permet de choisir le meilleur système de fusion de données. Nous définissons dans la suite les possibles défauts d'une information.

Imperfections des données Nous pouvons distinguer différents types d'imperfections (aussi développés dans [97, 23])

L'incertitude : l'incertitude d'une information est relative au degré de conformité à la réalité de l'information. Elle fait référence à la qualité des données. Par exemple la détection non systématique d'une cible est une incertitude liée au capteur.

L'imprécision : l'imprécision d'une information mesure un défaut quantitatif de connaissance. Elle concerne le manque d'exactitude en quantité, en taille, en durée ou encore la définition même de l'information qui est trop vague et ainsi ouverte à plusieurs interprétations.

L'incomplétude : l'incomplétude caractérise le manque d'information apporté par la source sur certains aspects du problème. Par exemple le champ de vue d'un capteur limite

l'information de la scène globale. L'incomplétude de plusieurs sources est une grande motivation pour la fusion. Le manque d'information d'une source peut être pallié par une autre.

L'ambigüité : l'ambigüité exprime la capacité d'une information à conduire à deux interprétations. Elle peut provenir des imperfections précédentes, comme l'imprécision d'une mesure ne permettant pas de différencier deux situations.

L'indépendance : L'indépendance entre deux sources est une hypothèse souvent faite. Il est rare de rencontrer une indépendance statistique des sources, car elles sont souvent de même nature, leur modélisation statistique est donc la même. Par contre, l'indépendance cognitive est moins restrictive. L'indépendance cognitive des sources est réalisée si chaque source n'a aucune information sur les autres sources, c'est-à-dire que chaque source fournit son information sans consulter les autres sources.

Relations entre les sources Ajouté aux termes précédents décrivant la qualité de l'information, nous pouvons aussi définir quelque termes qualifiant la relation entre plusieurs informations [6].

Le conflit : le conflit caractérise deux ou plusieurs informations conduisant à des interprétations contradictoires et donc incompatibles.

La redondance : la redondance est la qualité de sources qui apporte plusieurs fois la même information. Idéalement, la redondance est exploitée afin de lever des ambiguïtés.

La complémentarité : la complémentarité est la propriété des sources qui apportent des informations sur des grandeurs différentes. Elle permet d'obtenir une information plus globale, plus complète et peut aussi être utilisée afin de lever des ambiguïtés.

2.2.2 Différentes architectures de fusion

L'architecture d'un système de fusion est l'organisation de la chaîne de traitement.

Comme dit précédemment, la fusion d'information peut servir aussi bien à combiner des informations de sources différentes que des informations d'une source unique sur un intervalle de temps. Elle permet aussi l'association des deux, c'est à dire fusionner des informations de sources différentes sur un intervalle de temps. Concernant l'architecture de fusion, nous

pouvons distinguer deux architectures différentes pour le même système, l'architecture temporelle (la fusion s'effectue sur un intervalle de temps) et l'architecture spatiale (la fusion concerne plusieurs sources d'information).

2.2.2.1 Aspect temporel

La contrainte de temps réel peut être forte pour les systèmes de fusion, il faut réussir à traiter une grande quantité d'information provenant de plusieurs sources en temps réel. Cette contrainte peut fortement agir sur le choix de l'architecture, certaines architectures étant plus ou moins coûteuses en temps.

Dans les systèmes de fusion il faut aussi souvent gérer des sources d'information asynchrones avec des cadences différentes. Il faut alors soit ré-aligner temporellement ces informations (par une synchronisation des sources, voir Figure. 2.1), soit réussir à gérer cet asynchronisme dans le système de fusion. Nous pouvons distinguer deux types d'architecture temporelle, celle dite parallèle et celle de série. De même lorsque les données proviennent de prétraitements à partir des données de sources brutes, il faut pouvoir prendre en compte le décalage temporel (décalage entre l'instant où les données parviennent au système de fusion, et l'instant où elles ont été acquises).


Architecture parallèle Avec une architecture parallèle, les différentes informations sont synchronisées et traitées en même temps, cette architecture permet de mettre en évidence les consensus et les conflits.

Architecture série L'architecture série, aussi appelé architecture hiérarchique, ordonne les données à combiner. L'ensemble des informations est mis à jour par une nouvelle donnée.


2.2.2.2 Aspect spatial

Quand on parle de l'aspect spatial d'une architecture, on différencie deux types d'architectures : les systèmes centralisés, et les systèmes distribués [52] (voir Figure 2.2).


Fusion centralisée Pour une architecture centralisée, toutes les informations sont traitées et analysées dans un unique nœud de fusion[33]. Tous les capteurs lui sont reliés. Il n'y a pas de fusion intermédiaire. Par contre, la fusion dans cet unique centre peut s'effectuer de manière parallèle ou en série.



(a) Sur-échantillonnage



(b) sous-échantillonnage



(c) sans synchronisation

FIGURE 2.1 – Différents choix de synchronisation

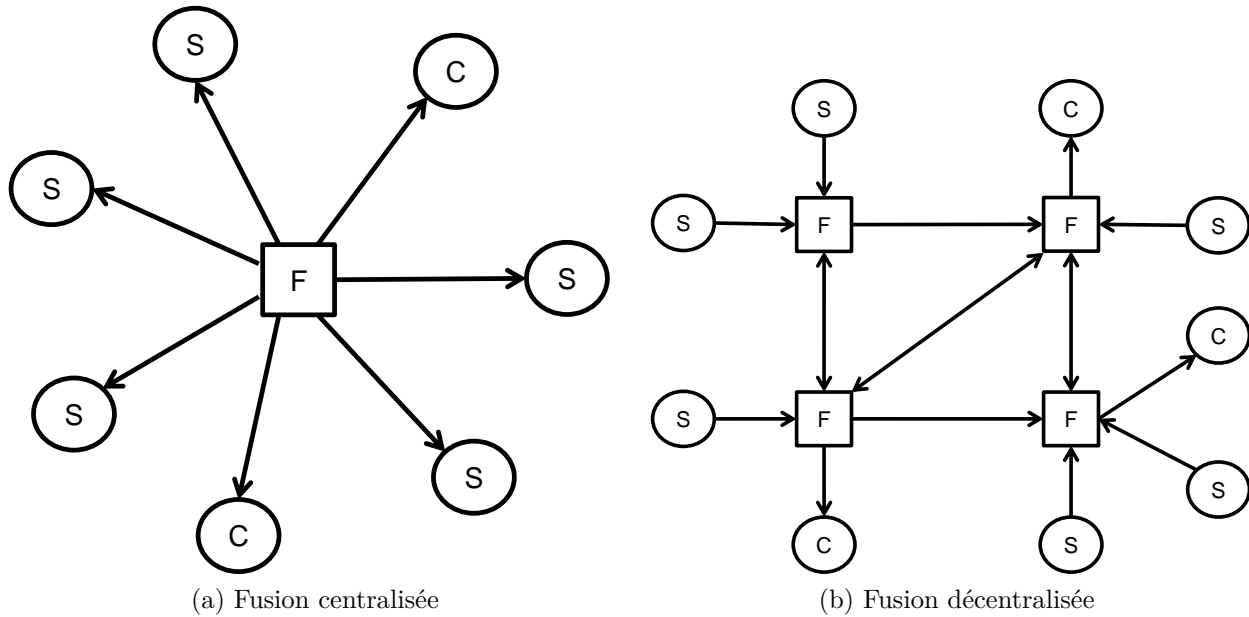


FIGURE 2.2 – architecture spatiale : F= nœud de fusion, S= Source de données, C=Consommateur d'information

Fusion distribuée Pour une architecture distribuée ou décentralisée, il y a plusieurs nœuds de fusion. Un nœud de fusion correspond à une partie du système de fusion. Ces nœuds échangent des informations entre eux, ils sont particulièrement adaptés pour des systèmes avec des nœuds de fusion géographiquement éloignés. L'avantage d'un système décentralisé vient de la robustesse du système en cas de perte d'un centre de fusion. Cette approche est par contre difficile à mettre en place vis à vis de la gestion des échanges entre les centres de fusion, il faut savoir gérer correctement la redondance d'information.

2.2.3 Différents niveaux de fusion

Un système de fusion peut être caractérisé en fonction du niveau de fusion. Le niveau de fusion correspond au niveau d'abstraction des données à fusionner. Dans la littérature, on parle en général de trois niveaux de fusion. Dasarathy en a en effet proposé trois, qui sont les données, les caractéristiques, et les décisions [15]. Ces trois niveaux ont été souvent repris [111]. Les données correspondent à la sortie directe, brute des capteurs, ce niveau de fusion est aussi appelé bas niveau. Pour une caméra par exemple, la fusion bas niveau correspondra à la fusion directe au niveau du pixel des images. Les caractéristiques correspondent au résultat d'un premier traitement des données brutes du capteur. Appelé aussi niveau intermédiaire ou d'attribut, ce niveau d'abstraction correspond à la fusion d'informations déduites des




FIGURE 2.3 – Différents niveaux d'abstraction de d'information pour la fusion

données des sources, comme les attributs de texture d'une image par exemple. Les décisions correspondent à un niveau d'abstraction plus élevée. Dite aussi fusion de haut niveau, cette architecture de fusion correspond à la fusion d'informations provenant d'un expert ou d'un système de décision, un classifieur par exemple. Il est important de noter que certains systèmes de fusion peuvent s'effectuer sur plusieurs niveaux.

2.2.4 Application

Dans la littérature, pour des applications routières semblables au sujet de ce mémoire, différents niveaux de systèmes de fusion sont décrits. Nous pouvons trouver dans [90] un exemple de fusion entre des données et des caractéristiques (les données brutes ont été traitées pour obtenir des attributs condensant l'information intéressante). Ainsi, la caméra détecte des obstacles grâce à l'utilisation d'un algorithme de soustraction de fond. Ces détections sont ensuite fusionnées avec le signal brut radar pour différencier les obstacles. Dans le même esprit, des caractéristiques provenant des images caméra peuvent être utilisées dans un système de fusion avec des données brutes radar afin de distinguer les détections intéressantes du radar par rapport aux fausses alarmes[100]. Dans [36], les caractéristiques des détections d'obstacle de la caméra sont aussi utilisées pour confirmer l'existence des détections radar, mais en plus de cette fonction, elles permettent de compléter la connaissance de l'état de chaque cible. Dans [41], les caractéristiques de la caméra ne participent pas aux décisions portant sur l'existence d'une cible, mais contribuent à décrire le contour des obstacles. Dans ce système de fusion, la complémentarité est particulièrement exploitée.

Il existe aussi dans la littérature et pour les mêmes applications routières des systèmes

de fusion utilisant directement les “décisions” des capteurs. Dans ces cas applicatifs, l'information de plus haut niveau renvoyée par les capteurs d'observation correspond à une liste de détections associées à des propriétés particulières (position, forme, classification, ...). Deux genres de fusion haut niveau combinant ce genre d'information peuvent être distingués. Tout d'abord la fusion dite de pistes, le principe de ce système de fusion est de d'associer les détections des différents capteurs après une première étape de synchronisation [67]. D'autres méthodes sont basées directement sur un algorithme de suivi d'obstacle [48]. Dans ce cas, le filtre de suivi d'obstacle est nourri par les sorties du capteur dès que le capteur renvoie des données sans attendre les données des autres capteurs. Dans la suite nous approfondirons les différentes méthodes existantes de suivi de piste.

Dans cette section nous avons défini quelques notions importantes de la fusion de données, nous avons aussi présenté différents types d'architectures de système de fusion de données. La définition d'une architecture de fusion dite “non synchronisée, centralisée et de haut niveau” permettant de gérer “l'incertitude des données, ainsi que des sources discordantes”, a été décrite. Nous allons dans la suite décrire l'ensemble des outils théoriques permettant concrètement de construire un système de fusion de données.

2.3 Approches pour le traitement de l'information

2.3.1 Notations

Notation	Signification
S_j	Source d'information numéro j
d_i	Décision numéro i que peut prendre le système de fusion
M_i^j	Information fournie par la source S_j sur une décision d_i
\emptyset	Ensemble vide

TABLE 2.1 – Notations générales utilisées pour les théories de fusion

2.3.2 Introduction

Cette section correspond à la description des trois théories les plus utilisées dans les domaines de traitement de l'information. Les paragraphes suivants peuvent être vus comme une description d'outils permettant de modéliser et d'estimer l'information, mais aussi de gérer la combinaison ainsi que la décision lors de la fusion en fonction de l'approche choisie. Nous verrons donc comment les différentes étapes de la fusion d'informations sont définies en fonction de la théorie. Pour chaque théorie, l'étape de modélisation de l'information, ainsi que les différentes méthodes d'estimation, de combinaison et de décision seront développées. Les différences et les implications de chaque théorie seront aussi partagées.

Pour décrire et expliquer chacune des approches de manière uniforme, nous nous plaçons dans le cadre d'un problème de traitement d'information classique. Nous disposons de l sources d'information S_1, S_2, \dots, S_l , et l'objectif est de prendre une décision parmi n décisions possibles d_1, d_2, \dots, d_n . L'information, appelée *measure*, renvoyée par une source S_j concernant la décision d_i est notée M_i^j .

2.3.3 La théorie des probabilités

2.3.3.1 Notations

Notation	Signification
Ω	Univers des possibles
A	Évènement
\bar{A}	Complémentaire de l'évènement A
$P(A)$	Probabilité de l'évènement A
$P(A B)$	Probabilité conditionnelle de A sachant B

TABLE 2.2 – Notations utilisées pour la théorie des probabilités

2.3.3.2 Introduction

La théorie des probabilités est l'étude mathématique des phénomènes caractérisés par la hasard et l'incertitude. Associée à l'approche bayésienne, c'est la théorie la plus exploitée dans les applications pratiques. L'approche bayésienne se réfère en fait à la méthode de combinaison utilisée. La théorie des probabilités permet un cadre mathématique rigoureux, c'est aussi un formalisme bien établi qui bénéficie de nombreux travaux dans le domaine. Beaucoup de méthodes de combinaison et de décision sont donc connues [81] et permettent de résoudre la majorité des problèmes rencontrés.

2.3.3.3 Généralités

Définition Probabilité Tout d'abord voyons quelques définitions et notations utilisées dans la suite. Lors d'une expérience aléatoire, l'ensemble des résultats possibles est appelé l'univers des possibles, noté Ω . Chaque élément de cet ensemble est appelé éventualité, noté w . Une éventualité est donc un résultat possible de l'expérience.

En termes mathématiques, une probabilité sur un ensemble fini Ω est une application de Ω dans $[0, 1]$. La probabilité d'un évènement A est définie par la probabilité de l'ensemble des éventualités formant l'évènement A .

$$P(A) = \sum_{w \in A} P(w)$$

Une mesure de probabilité vérifie les propriétés élémentaires suivantes :

- La probabilité de l'ensemble vide est nulle et celle de l'univers est égale à 1

$$P(\emptyset) = 0$$

$$P(\Omega) = 1$$

- Soit \bar{A} l'évènement complémentaire de A , alors la confiance non accordée à l'évènement

A est directement accordée à \bar{A}

$$\forall A \in \Omega, P(\bar{A}) = 1 - P(A)$$

– La probabilité de l'union de deux évènements est donnée par :

$$\forall A, B \in \Omega, P(A \cup B) = P(A) + P(B) - P(A \cap B) \quad (2.1)$$

Si l'intersection des deux évènements est vide ($A \cap B = \emptyset$), alors l'équation 2.1 devient :

$$\forall A, B \in \Omega, P(A \cup B) = P(A) + P(B)$$

Probabilité conditionnelle Soit A et B deux évènements de l'univers Ω . En théorie des probabilités, la probabilité conditionnelle de l'évènement A , sachant que l'évènement B de probabilité non nulle s'est réalisé (ou probabilité de A , sachant B), notée $P(A|B)$, est égale à la probabilité de l'intersection de A et B divisée par la probabilité de B .

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Loi des probabilités totales Une partition de l'univers Ω est par définition un ensemble d'évènements B_1, B_2, \dots, B_n exclusifs et exhaustifs. Des évènements B_1, B_2, \dots, B_n sont dit exclusifs s'ils sont disjoints deux à deux c'est à dire si $\forall i, j$ tel que $i \neq j$, $B_i \cap B_j = \emptyset$. De même les évènements B_1, B_2, \dots, B_n sont dit exhaustifs si la réunion de ses évènements forment l'univers, c'est à dire si $B_1 \cup B_2 \cup \dots \cup B_n = \Omega$.

Théorème 1. *Formule des probabilités totales : soit une partition B_1, B_2, \dots, B_n de Ω , alors pour tout évènement A de Ω :*

$$P(A) = \sum_{i=1}^n P(A \cap B_i) = \sum_{i=1}^n P(A|B_i)P(B_i).$$

Cette formule peut s'illustrer par le diagramme de la Figure 2.4 dans le cas particulier d'une partition de 3 évènements.

Théorème de Bayes

Théorème 2. *Soient A et B deux évènements tel que $P(B) > 0$, alors*




FIGURE 2.4 – Loi des probabilités totales




FIGURE 2.5 – Théorème de Bayes

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Cette formule permet de lier les probabilités conditionnelles $P(A|B)$ et $P(B|A)$.

D'autres versions de ce théorème peuvent être notées. En particulier celle concernant une partition de Ω . En effet, soient B_1, B_2, \dots, B_n une partition de Ω , soit A , un évènement tel que $P(A) > 0$, alors

$$\forall i \in 1, 2, \dots, n, P(B_i|A) = \frac{P(A|B_i)P(B_i)}{\sum_j P(A|B_j)P(B_j)}$$

Ce théorème est illustré sur la Figure 2.5. La probabilité de B_i sachant A est égale à la probabilité du morceau bleu foncé divisé par la somme de tous les morceaux bleus.

Indépendance Deux évènements sont dits indépendants si :

$$P(A \cap B) = P(A)P(B)$$

Si deux évènements A et B sont indépendants, on a :

$$P(A|B) = P(A)$$

Cela signifie que la connaissance de B n'influence pas la connaissance de A (et vice versa).

2.3.3.4 Modélisation

Les paragraphes précédents décrivent les bases générales de la théorie des probabilités sans aucun *a priori* de l'application (la fusion d'informations par exemple). Nous commençons dans ce paragraphe à développer les outils de la théorie de la probabilité utilisés dans le cadre de la fusion d'information.

Nous avons vu dans le paragraphe 2.2.1.1 que les différents systèmes de fusion d'informations pouvaient se décrire en 4 phases : la modélisation, l'estimation de modèle, combinaison, décision. Nous allons donc commencer par la première : la modélisation. L'information à fusionner est modélisée dans la théorie des probabilités par une probabilité conditionnelle. Dans cette approche, les décisions sont obligatoirement exclusives et exhaustives.

Ainsi la mesure M_i^j introduite dans le début du chapitre 2.3 s'écrit :

$$M_i^j = P(d_i|S_j)$$

On prend ici et dans la suite l'exemple de deux capteurs essayant de savoir si une personne est dans un espace donné. L'univers des possibles est donc défini par $\Omega = \{C, \overline{C}\}$. C correspond à l'évènement "il y a une cible", le terme cible renvoyant à une personne, alors que \overline{C} correspond à l'évènement, "il n'y a pas de cible". Les capteurs S_1 et S_2 renvoient une mesure concernant la présence ou non d'une cible.

2.3.3.5 Estimation

Pour rappel, nous parlons dans ce paragraphe de l'estimation du modèle à utiliser dans le système de fusion, c'est à dire, par exemple, l'estimation des probabilités ou des distributions de probabilité effectuée lors de la construction du système de fusion.

La distribution $P(d_i|S_j)$ est rarement connue, l'estimation de cette distribution est alors nécessaire.

En général on utilise le théorème de Bayes pour estimer $P(d_i|S_j)$.

$$P(d_i|S_j) = \frac{P(S_j|d_i)P(d_i)}{P(S_j)}$$

	C	\overline{C}
$S_1 = 1$	$P(S_1 = 1 C)$	$P(S_1 = 1 \overline{C})$
$S_1 = 0$	$P(S_1 = 0 C)$	$P(S_1 = 0 \overline{C})$

TABLE 2.3 – Exemple de notation pour représenter les probabilités

	C	\overline{C}
$S_1 = 1$	0.75	0.1
$S_1 = 0$	0.25	0.9
$S_2 = 1$	0.85	0.4
$S_2 = 0$	0.15	0.6

TABLE 2.4 – Vraisemblance de l'exemple.

$P(S_j|d_i)$ est appelée la vraisemblance, $P(d_i)$ est appelée la probabilité *a priori* alors que $P(d_i|S_j)$ est appelée la probabilité *a posteriori*.

Deux cas se présentent pour estimer ces précédentes distributions.

Cas discret L'apprentissage des différentes distributions s'appuie alors sur des outils statistiques classiques (dénombrement...).

Cas continu Les distributions sont estimées par des distributions connues. Les distributions gaussiennes sont généralement utilisées. Ce choix se justifie grâce au théorème de la limite centrale (qui affirme que toute somme de variables aléatoires indépendantes et identiquement distribuées tend vers une variable aléatoire gaussienne). Le problème d'estimation est alors réduit au problème d'estimation des deux premiers moments.

Exemple : Si l'on reprend l'exemple précédent. Nous cherchons à estimer les valeurs du tableau 2.3.

$P(S_1 = 1|C)$, est la vraisemblance que la source 1 détecte une cible sachant qu'il y a réellement une cible. Cette valeur provient d'un apprentissage, on regarde la réponse de la source 1 lorsque qu'il y a une cible. Imaginons que sur 1000 tests où il y a une cible, la source 1 détecte 750 fois la cible, on affecte donc la valeur 0.75 à cette vraisemblance. On fait la même chose pour chaque valeur du tableau. On obtient alors le tableau 2.4.

2.3.3.6 Combinaison

La combinaison est l'étape du système de fusion qui permet de mélanger, de combiner les informations.

Nous présentons ici deux types de combinaison [6]. La première s'appuie sur la règle de Bayes, la seconde cherche à combiner les probabilités par différents types d'opérateurs.

Combinaison Bayésienne Lorsque l'on parle communément d'approche de fusion bayésienne, cela signifie que l'étape de combinaison de la fusion est définie à partir de la règle de Bayes.

Dans ce cas, la combinaison des informations pour la théorie des probabilités peut s'effectuer de deux manières différentes :

- la fusion s'effectue au niveau de la modélisation, on recherche directement à calculer $P(d_i|S_1, \dots, S_l)$ par :

$$P(d_i|S_1, \dots, S_l) = \frac{P(S_1, \dots, S_l|d_i)P(d_i)}{P(S_1, \dots, S_l)}$$

où les différentes probabilités sont alors à estimer dans l'étape d'estimation de modèle (par apprentissage par exemple). Dans ce cas, la fusion nécessite des informations de sources différentes simultanément.

- la fusion peut aussi s'effectuer à l'arrivée d'une nouvelle information, de façon adaptative. Par la règle de Bayes, l'information d'une source vient mettre à jour l'information estimée d'après les sources précédentes

$$P(d_i|S_1, \dots, S_l) = \frac{P(S_1|d_i)P(S_2|S_1, d_i) \cdots P(S_l|S_1, \dots, S_{l-1}, d_i)P(d_i)}{P(S_1)P(S_2|S_1) \cdots P(S_l|S_1, \dots, S_{l-1})} \quad (2.2)$$

Dans ce cas les sources peuvent émettre les informations de manière successive (contrairement au cas précédent).

Les différentes distributions utilisées par le modèle peuvent être estimées dans l'étape d'estimation. Cette tâche est souvent difficile car elle nécessite un grand nombre de données pour l'apprentissage de l'ensemble des différentes distributions. L'équation 2.2 peut parfois être simplifiée en faisant l'hypothèse d'indépendance statistique des sources conditionnellement à une décision. Elle devient :

$$P(d_i|S_1, \dots, S_l) = \frac{\prod_{j=1}^l P(S_j|d_i)P(d_i)}{\prod_{j=1}^l P(S_j)}$$

S_1	S_2	$P(C S_1, S_2)$	$P(\overline{C} S_1, S_2)$
0	0	0.0649	0.9351
0	1	0.3712	0.6288
1	0	0.6522	0.3478
1	1	0.9410	0.0590

TABLE 2.5 – Exemple de calcul de la probabilité qu'il y ait une cible ou non en fonction des mesures des deux sources

Combinaison des probabilités D'autres choix peuvent être faits pour combiner les informations des différentes sources. Considérant la probabilité $P(d_i|S_j)$ pour chaque source j , la probabilité d'avoir la décision d_i peut être calculée. Pour cela, les opérateurs classiques de combinaison peuvent être utilisés, le maximum, le minimum, la moyenne, la médiane,...[125, 47, 46].

Exemple : On continue sur l'exemple précédent, regardons le résultat de la combinaison pour l'ensemble des résultats possibles des sources 1 et 2 (voir le tableau 2.5).

Par exemple, pour la première ligne du tableau 2.5, les deux sources n'ont pas détecté de cible ($S_1 = 0$, et $S_2 = 0$), nous cherchons à calculer la probabilité qu'il y ait ou non une cible.

Sans aucune information, on considère que $P(C) = 0.5$ et $P(\overline{C}) = 0.5$, on calcule alors :

$$\begin{aligned}
 P(C|S_1 = 0, S_2 = 0) &= \frac{P(S_1=0|C) \cdot P(S_2=0|C)P(C)}{P(S_1=0, S_2=0)} \\
 &= \frac{P(S_1=0|C) \cdot P(S_2=0|C)P(C)}{P(S_1=0|C)P(S_2=0|C)P(C) + P(S_1=0|\overline{C})P(S_2=0|\overline{C})P(\overline{C})} \\
 &= \frac{0.25 \cdot 0.15 \cdot 0.5}{0.25 \cdot 0.15 \cdot 0.5 + 0.9 \cdot 0.6 \cdot 0.5} \\
 &= 0.0649
 \end{aligned}$$

On effectue le même processus pour remplir les autres lignes du tableau.

2.3.3.7 Décision

L'étape de décision consiste à choisir la décision d_k parmi l'ensemble des décisions possibles qui correspond le mieux aux informations provenant des sources S_j . Cette fois encore, différentes règles peuvent être employées. La plus utilisée est celle du maximum de probabilité *a posteriori*, d_k est choisie si :

$$P(d_k|S_1, \dots, S_l) = \max_{i \in [1, \dots, n]} P(d_i|S_1, \dots, S_l)$$

De nombreux autres critères peuvent également être cités comme le maximum de vraisemblance ou encore le maximum d'entropie. Le choix du critère de décision se fait généralement en fonction des choix précédents effectués (choix de modélisation et de combinaison).

Exemple : Si l'on reprend l'exemple précédent, pour le cas où $S_1 = 1$ et $S_2 = 0$, nous décidons qu'il y a une cible car $0.6522 = P(C|S_1 = 1, S_2 = 0) > P(\bar{C}|S_1 = 1, S_2 = 0) = 0.3478$ (voir le tableau 2.5). La probabilité qu'il y ait une cible est supérieure à la probabilité qu'il n'y ait pas de cible sachant que la première source détecte une cible alors que la deuxième source ne détecte rien.

2.3.3.8 Limites et intérêts

Comme il a été dit dans l'introduction, la théorie des probabilités permet un cadre rigoureux à la fusion. Les approches probabilistes sont bien connues et utilisées depuis longtemps, cela permet une grande diversité de méthodes de combinaisons et de décisions, ce qui permet aux approches probabilistes d'être optimales dans un certain nombre d'applications. Cependant, ces méthodes présentent également certains inconvénients. Le problème majeur des probabilités est qu'elles représentent essentiellement l'incertitude et très mal l'ignorance.

De plus, l'estimation des probabilités est une étape difficile à réaliser car pour être efficace (faible erreur sur l'estimation des probabilités), elle doit se baser sur un nombre important de données. Nous pouvons dire aussi que l'hypothèse d'indépendance effectuée lors de l'étape de combinaison peut être un problème avec certaines applications.

De plus, le monde des décisions doit être fermé, c'est à dire que l'ensemble des sources et hypothèses doit être connu et défini.

Pour finir, la modélisation de certaines données peut aussi être compliquée, par exemple l'absence de connaissance est difficile à modéliser avec des probabilités. Pour bien expliquer ce problème, voici un exemple tiré de [60].

Supposons que l'ignorance sur l'existence d'une cible à détecter peut se modéliser par $p(cible) = p(noncible) = 0.5$. Si le problème est posé de manière différente et que l'important est la détection de cibles ennemies, c'est-à-dire qu'il peut y avoir une cible amie, ennemie, ou ne pas y avoir de cibles, l'ignorance peut alors être modélisée par $p(cible_{amie}) = p(cible_{ennemie}) = p(noncible) = 1/3$ et donc $p(cible) = 2/3$. Il est ainsi possible par un raisonnement analogue d'exprimer cette probabilité par autant de valeurs que de façons d'aborder le problème.

Dans la théorie des croyances ce problème est contourné. En effet, la théorie de l'évidence

de Dempster-Shafer introduit des masses permettant de caractériser le degré de confiance d'une mesure, d'un modèle ou d'une hypothèse.

Cette théorie est développée dans le paragraphe 2.3.4.

2.3.4 La théorie des croyances

2.3.4.1 Notations

Notation	Signification
Ω	Cadre de discernement
A	Proposition
m	Fonction de masse
Cr	Fonction de croyance
Pl	Fonction de plausibilité
$BetP$	Probabilité pignistique
$ A $	Cardinal de A

TABLE 2.6 – Notations utilisées pour la théorie de l'évidence

2.3.4.2 Introduction

La théorie de l'évidence, nommée aussi théorie des fonctions de croyance de Dempster-Shafer, s'appuie sur les travaux de A.P.Dempster [18] qui ont été formalisés par G.Shafer[93]. Cette méthode repose sur la modélisation de la croyance en un évènement. Cette théorie permet de modéliser l'incertitude, mais aussi l'imprécision. Elle tient compte également des ambiguïtés et des conflits entre les sources. Dezert et Smarandache[20, 21] ont proposé une extension coûteuse en calcul dans le cas où le conflit entre les sources est important.

2.3.4.3 Modélisation

La théorie des croyances repose sur la définition de fonctions de masse, de croyance et de plausibilité. Contrairement à la théorie des probabilités (avec des fonctions définies sur des singletons), ces fonctions sont définies sur des sous ensembles du cadre de discernement Ω . L'espace de définition D de ces fonctions correspond à l'ensemble des disjonctions des éléments de Ω . Par exemple pour $\Omega = \{d_1, d_2, d_3\}$, on a

$$D = \{\emptyset, \{d_1\}, \{d_2\}, \{d_3\}, \{d_1, d_2\}, \{d_1, d_3\}, \{d_2, d_3\}, \{d_1, d_2, d_3\}\}$$

dont le cardinal est $|D| = 2^{|\Omega|}$. Dans la généralisation de Dezert-Smarandache, l'ensemble de définition correspond à l'ensemble des sous ensembles possibles formés à partir de l'intersection de deux éléments de D .

Fonction de masse Une fonction de masse est une fonction définie sur D à valeur dans $[0, 1]$. La fonction de masse $m_j(A)$ caractérise le degré de croyance en la proposition A ($A \in D$), étant donnée une source S_j . Cette fonction vérifie en général par construction :

$$\sum_{A \in D} m_j(A) = 1$$

Si on fait l'hypothèse que toutes les décisions possibles sont connues et représentées dans D , autrement dit, si on fait l'hypothèse d'un *monde fermé*, on a alors :

$$m_j(\emptyset) = 0$$

Si au contraire on veut pouvoir modéliser l'inconnu, le fait qu'il est possible que la décision ne soit pas comprise dans D , on parle alors d'un *monde ouvert*, (hypothèse choisie par Smets [95]). On a alors :

$$m_j(\emptyset) > 0$$

Contrairement à la théorie des probabilités, l'ignorance peut être modélisée lorsque $m_j(\Omega) > 0$. $m_j(\Omega) = 1$ correspond à une ignorance totale, c'est à dire l'on sait que la décision appartient à Ω , mais on n'a pas d'information supplémentaire.

Fonction de croyance Une fonction de croyance est une fonction définie sur D à valeur dans $[0, 1]$. La fonction de croyance $Cr_j(A)$ caractérise le degré de croyance minimale en la proposition A ($A \in D$), étant donnée une source S_j . Elle vérifie $Cr_j(\emptyset) = 0$ et pour tout A_1, \dots, A_k on a :

$$Cr_j\left(\bigcup_{i=1}^k A_i\right) > \sum_{I \subseteq \{1, \dots, k\}, I \neq \emptyset} (-1)^{|I|+1} Cr_j\left(\bigcap_{i \in I} A_i\right)$$

Cette fonction de croyance peut aussi se construire à partir de la fonction de masse associée à la même source m_j . La fonction de croyance de l'ensemble A correspond ainsi à la somme des valeurs de fonction de masse de toutes les disjonctions possibles des éléments de l'ensemble A :

$$Cr_j(A) = \sum_{B \subseteq A, B \neq \emptyset} m_j(B)$$

Fonction de Plausibilité Une fonction de plausibilité est une fonction définie sur D à valeur dans $[0, 1]$. Cette fonction a été introduite dans [93] sous l'hypothèse d'un monde fermé, elle a ensuite été étendue. La fonction de plausibilité Pl_j caractérise le degré de croyance maximale en la proposition A ($A \in D$), étant donnée une source S_j . Elle est définie pour tout $A \in D$ par :

$$Pl_j(A) = \sum_{B \cap A \neq \emptyset} m_j(B)$$

Elle peut aussi être définie à partir de la fonction de croyance :

$$Pl_j(A) = Cr_j(\Omega) - Cr_j(\overline{A})$$

où \overline{A} est le sous ensemble de Ω , complémentaire du sous ensemble A .

Remarques générales

- L'intervalle $[Cr_j(A), Pl_j(A)]$ est appelé intervalle de confiance et sa longueur est une mesure de l'ignorance que l'on a sur l'évènement A .
- Les trois fonctions de masse, de croyance et de plausibilité peuvent être ramenées à une même mesure de probabilité lorsque que l'on affecte une masse uniquement aux éléments simples de D , c'est à dire, pour tout $A \in D$, tel que $|A| > 1$, alors $m_j(A) = 0$.
- D'autres fonctions ont été définies dans la littérature pour caractériser les évènements dans le cadre de la théorie de croyances : *la fonction de communalité*, introduite par Dempster [18] et nommée par Shafer [93], *la fonction de d'implicabilité*, introduite par Smet [98] et *la fonction de non croyance*, introduite dans [93].

Exemple : Considérons l'exemple de deux capteurs essayant de savoir si une personne est dans un espace donné. L'univers des possibles est donc défini par $\Omega = \{C, \overline{C}\}$. Le référentiel de définition est donc : $D = \{\emptyset, C, \overline{C}, \Omega\}$ C correspond à l'évènement "il y a une cible", alors que \overline{C} correspond à l'évènement, "il n'y a pas de cible". Les capteurs S_1 et S_2 renvoient une mesure concernant la présence ou non d'une cible.

2.3.4.4 Estimation du modèle

L'étape d'estimation du modèle est une étape difficile de la théorie des fonctions de croyance. Différentes méthodes d'estimation de la fonction de masse existent dans la littérature. Le choix est fait alors en fonction des données à traiter et de l'application envisagée. Il existe ainsi des approches modélisant des sources apportant de l'information sur un seul des éléments de D , par exemple, les fonctions à support simple [93], ou les fonctions de croyance complémentaire [126]. Les fonctions de masse peuvent aussi se définir uniquement sur les singletons, ces cas se rapprochent alors des probabilités [50]. Cette liste est loin d'être exhaustive, l'un des avantages de la théorie des fonctions de croyance étant le nombre important des possibilités de modélisation.

Exemple : On reprend l'exemple 2.3.4.3, on peut estimer par apprentissage la fonction de masse de chaque source.

On notera les fonctions de masse telles que : $m = \begin{bmatrix} \emptyset & C & \overline{C} & \Omega \\ m(\emptyset) & m(C) & m(\overline{C}) & m(\Omega) \end{bmatrix}$.

On choisi l'exemple suivant, une des sources étant un peu ignorante :

$$m_1 = \begin{bmatrix} \emptyset & C & \overline{C} & \Omega \\ 0 & 0.9 & 0 & 0.1 \end{bmatrix} \text{ et } m_2 = \begin{bmatrix} \emptyset & C & \overline{C} & \Omega \\ 0 & 0.1 & 0 & 0.9 \end{bmatrix}$$

2.3.4.5 Combinaison

La combinaison comme pour la théorie des probabilités correspond à la méthode permettant de combiner plusieurs informations concernant le même sous ensemble de décisions et provenant de plusieurs sources différentes, nous cherchons donc à combiner les fonctions de masse m_1, \dots, m_l

Pour l'étape de combinaison il existe aussi de nombreuses méthodes possibles. Ces différentes méthodes de combinaison peuvent être classées selon si elles sont conjonctives, disjonctives, ou mixtes (un mélange des deux méthodes précédentes)[25, 96].

Combinaison conjonctive Une combinaison est dite conjonctive si elle considère les intersections des éléments de D . Dans la suite nous allons utiliser la règle orthogonale de Dempster Shafer comme exemple de règle de combinaison conjonctive. elle est définie par :

$$m(A) = (m_1 \odot \dots \odot m_l)(A) = \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1) \dots m_l(B_l)$$

- cette règle est commutative

$$\forall m_1, m_2; m_1 \odot m_2 = m_2 \odot m_1$$

- cette règle est associative

$$\forall m_1, m_2, m_3; (m_1 \odot m_2) \odot m_3 = m_1 \odot (m_2 \odot m_3)$$

- l'élément neutre de cette règle est

$$\begin{cases} m_0(D) = 1, \\ m_0(A) = 0, \forall A \in D, A \neq D \end{cases}$$

Remarque. 1 Problème rencontré.

Sous cette forme la règle de Dempster Shafer permet une masse non nulle à l'ensemble vide, i.e. $m(\emptyset) > 0$, ce qui, avec un monde défini fermé n'est pas autorisé. C'est pourquoi, une nouvelle forme de cette règle à été construite, appelé la règle normalisée de Dempster :

$$\begin{cases} m_{norm}(A) = \frac{1}{1-m(\emptyset)} \sum_{B_1 \cap \dots \cap B_l = A} m_1(B_1) \dots m_l(B_l) \text{ si } A \neq \emptyset, \\ m_{norm}(\emptyset) = 0 \end{cases}$$

Cette nouvelle fonction permet de s'affranchir du problème précédemment évoqué mais, en cas de conflit de source, elle masque celui ci.

Combinaison disjonctive D'autres approches de combinaison peuvent être utilisées, telle que la combinaison disjonctive [99]. La combinaison m est alors définie par :

$$m(A) = (m_1 \odot \dots \odot m_l)(A) = \sum_{B_1 \cup \dots \cup B_l = A} m_1(B_1) \dots m_l(B_l)$$

Cette règle a des propriétés similaires à la combinaison conjonctive, elle est commutative, associative, mais son élément neutre est la règle définie par :

$$\begin{cases} m_\emptyset(\emptyset) = 1, \\ m_\emptyset(A) = 0, \forall A \in D, A \neq \emptyset \end{cases}$$

Exemple : Exemple d'application de la règle conjonctive utilisant les fonctions de masse estimées dans l'exemple 2.3.4.4.

On a alors grâce au tableau 2.7 :

$$m = m_1 \odot m_2 = \begin{bmatrix} \emptyset & C & \overline{C} & \Omega \\ 0 & 0.09 + 0.01 + 0.81 = 0.91 & 0 & 0.09 \end{bmatrix}$$

$m(A \cap B)$ A	B $m_2(B)$	\emptyset 0	C 0.1	\overline{C} 0	Ω 0.9
\emptyset 0		\emptyset 0	\emptyset 0	\emptyset 0	\emptyset 0
C 0.9		\emptyset 0	C $0.1 \cdot 0.9 = 0.09$	\emptyset 0	C $0.9 \cdot 0.9 = 0.81$
\overline{C} 0		\emptyset 0	\emptyset 0	\overline{C} 0	\overline{C} 0
Ω 0.1		\emptyset 0	C $0.1 \cdot 0.1 = 0.01$	\overline{C} 0	Ω $0.1 \cdot 0.9 = 0.09$

TABLE 2.7 – Exemple d'attribution des masses de la fusion conjonctive

Pour d'autres exemples pratiques de combinaison sur des exemples simples il est intéressant de lire la thèse de Julien Moras [65].

2.3.4.6 Décision

Pour cette étape, nous cherchons à choisir la décision d_i parmi l'ensemble des décisions de départ. Pour cela différentes méthodes peuvent être employées. Ce choix peut se faire par la maximisation d'un critère (le maximum de plausibilité, le maximum de croyance...). On peut aussi se ramener à des probabilités comme critère de décision. Une probabilité décrivant l'ensemble des singletons de l'ensemble est définie à partir de la fonction de masse, appelée probabilité pignistique $BetP$.

Cette transformation est définie :

$$\forall A \in \Omega, BetP(A) = \sum_{B \in D} \frac{|B \cap A|}{|B|} \cdot \frac{m(B)}{1 - m(B)}$$

A partir de la probabilité pignistique les outils de décision de la théorie des probabilités peuvent être utilisés.

Exemple : Nous présentons ci-dessous la probabilité pignistique des possibles événements C et \overline{C} . La décision peut ensuite être déduite des valeurs de cette probabilité.

$$BetP(C) = 0.955$$

$$BetP(\overline{C}) = 0.045$$

Si on considère la probabilité pignistique, l'évènement C est considéré.

2.3.4.7 Limites et Intérêts

L'intérêt de la théorie de croyance provient de la multitude de choses possibles. Il vient aussi de la possibilité de modéliser l'imprécision et l'incertitude. Un des défauts de cette méthode est lié à son plus grand avantage, l'espace de départ est plus important que celui des probabilités, cela peut entraîner par conséquent un coût de calcul. Dans le même genre d'idée on peut aussi noter la difficulté d'agir dans un domaine continu. Certain travaux ont été réalisés dans un cadre continu [89] et cela passe par un travail sur des intervalles, ce qui peut rapidement être très lourd en calcul.

2.3.5 La théorie des possibilités

2.3.5.1 Notations

Notations	Signification
μ	Fonction d'appartenance
h	Hauteur
Π	Mesure de possibilité
N	Degré de nécessité
π	Distribution de possibilité

TABLE 2.8 – Notations utilisées pour les ensembles flous et la théorie des possibilité

2.3.5.2 Introduction

La théorie des possibilités s'appuie sur la théorie des ensembles flous développée dans les années 60 par Zadeh[127]. L'intérêt de cette théorie est de ne pas être contraint par l'axiome des probabilités totales. Elle permet aussi de représenter imprécision et incertitude des capteurs. Pour plus de précision sur cette théorie, le lecteur pourra se rapporter aux documents [24, 6].

2.3.5.3 Généralités

Avant de voir comment cette théorie peut s'appliquer dans le cadre de la fusion d'informations, nous allons d'abord rappeler quelques définitions de notions importantes.

Théorie des ensembles flous En présence d'un ensemble classique, un élément appartient ou non à un sous ensemble, la fonction d'appartenance est donc binaire, soit $x \in A$ soit $x \notin A$. La théorie des ensembles flous repose sur le principe qu'il y a des degrés d'appartenance. Les limites entre deux sous ensembles, ou classes, sont floues, i.e. elles ne sont plus strictes. L'élément x peut donc être *un peu* dans l'ensemble A .

Ainsi on définit une fonction d'appartenance μ_A comme une fonction de D dans $[0, 1]$, qui pour tout élément $x \in D$ caractérise le degré d'appartenance de x à A .

Par simplification, les sous ensembles flous sont aussi appelés ensembles flous.

Définition du support Le support d'un ensemble flou A est l'ensemble des éléments appartenant au moins un peu à A .

$$Supp(A) = \{x \in A : \mu_A(x) > 0\}$$

Définition de la hauteur La hauteur d'un ensemble flou est la valeur maximale d'appartenance des éléments du support du sous ensemble flou A .

$$h(A) = \sup_{x \in A} \mu_A(x)$$

Définition du noyau Le noyau d'un ensemble flou A est le sous ensemble composé d'éléments appartenant totalement à A .

$$Noy(A) = \{x \in A : \mu_A(x) = 1\}$$

Théorie des possibilités

Définition d'une distribution de possibilité Le cadre de discernement Ω est un ensemble net (pas flou). Une distribution de possibilité est donc une fonction définie sur Ω à valeur dans $[0, 1]$. La distribution de possibilité π permet d'attribuer un degré de possibilité à tout élément de Ω .

Cette fonction vérifie en général par construction :

$$\sup \{\pi(A), A \in \Omega\} = 1$$

La fonction d'appartenance d'un ensemble flou peut être alors interprétée comme une distribution de possibilité.

Définition d'une mesure de possibilité Une mesure de possibilité est une fonction de D à valeur dans $[0, 1]$. Elle est notée Π . Soit A un élément de D , $\Pi(A) = 0$, signifie que l'évènement est impossible, alors que $\Pi(A) = 1$ signifie que l'évènement est possible, mais il n'est pas certain.

Quelques propriétés :

- La mesure de possibilité de l'ensemble vide est nulle.

$$\Pi(\emptyset) = 0$$

- La mesure de possibilité de Ω est égale à 1.

$$\Pi(\Omega) = 1$$

- La mesure de possibilité d'une disjonction est le maximum des mesures de possibilité des deux ensembles.

$$\forall A, B \in D, \Pi(A \cup B) = \max(\Pi(A), \Pi(B))$$

Mesure de possibilité et distribution sont liées par les relations suivantes :

$$\forall A \in D, \Pi(A) = \sup_{x \in A} \pi(x)$$

$$\forall B \in \Omega, \pi(B) = \Pi(B)$$

Définition d'un degré de nécessité Le degré de nécessité d'un évènement est une fonction de D à valeur dans $[0, 1]$. Elle est notée N . Soit A un élément de D , $N(A) = 1$ signifie que l'évènement est certain.

Relation avec le degré de possibilité :

- Pour un même évènement, le degré de possibilité est toujours inférieur au degré de nécessité.

$$\Pi(A) < N(A)$$

- Le degré de nécessité d'un évènement peut se définir à partir du degré de possibilité de l'évènement contraire.

$$N(A) = 1 - \Pi(A)$$

Modélisation Deux types de modélisation sont possibles pour résoudre le problème exposé en début de chapitre 2.3. La mesure peut être représentée par une fonction d'appartenance,

$$M_i^j = \mu_i^j$$

μ_i^j est la fonction représentant le degré d'appartenance à la décision d_i selon la source S_j . Ω l'ensemble des décisions, est alors un ensemble flou.

Contrairement à cette modélisation (avec des ensembles flous), une modélisation utilisant la théorie des possibilités permet de modéliser explicitement l'imprécision et l'incertitude à travers l'utilisation des degrés de possibilité et de nécessité. Dans ce cadre, la mesure introduite dans le début du chapitre M_i^j s'écrit :

$$M_i^j = \pi_j(d_i)$$

$\pi_j(d_i)$ représente le degré de possibilité de la décision d_i selon la source S_j . Cette modélisation suppose alors que l'ensemble des décisions est un ensemble net.

Exemple : Considérons l'exemple de deux capteurs essayant de savoir si une personne est dans un espace donné. L'univers des possibles est donc défini par $\Omega = \{C, \overline{C}\}$. Le référentiel de définition est donc : $D = \{\emptyset, C, \overline{C}, \Omega\}$ C correspond à l'évènement "il y a une cible", alors que \overline{C} correspond à l'évènement, "il n'y a pas de cible". Les capteurs S_1 et S_2 renvoient une mesure concernant la présence ou non d'une cible.

2.3.5.4 Estimation du modèle

L'estimation des fonctions d'appartenance relève plus du domaine de l'expertise que des statistiques. Cela permet une plus grande liberté de choix (pas besoin de satisfaire l'axiome des probabilités totales), mais cela entraîne aussi une plus grande difficulté pour la définition.

Exemple : Nous considérons le degré de possibilité qu'il y ait une personne ou non selon deux sources. Ces valeurs de possibilités sont obtenues par expertise ou apprentissage.

Nous avons donc les valeurs :

$$\begin{aligned}\pi_1(C) &= 0.8, \pi_1(\overline{C}) = 0.6 \\ \pi_2(C) &= 0.3, \pi_2(\overline{C}) = 0.9\end{aligned}$$

2.3.5.5 Combinaison

Dans ce paragraphe, nous allons décrire les opérateurs de combinaison utilisés dans le cadre de la théorie des possibilités. Cette théorie propose un grand nombre d'opérateurs, la

liste d'opérateurs décrite dans la suite n'est pas exhaustive, mais est composée des principaux opérateurs de la littérature [71]. Nous cherchons donc à combiner les différentes distributions de probabilités π_1, \dots, π_l . Nous notons π la distribution résultant de la combinaison.

Combinaison conjonctive \wedge L'opérateur conjonctif est particulièrement utile pour combiner des informations sans conflit, c'est à dire lorsque les sources sont concordantes. Un opérateur est conjonctif, lorsque c'est un opérateur d'intersection, comme le minimum ou le produit. Le résultat de la combinaison sera proche de 1 si et si l'ensemble des valeurs à combiner est proche de 1.

$$\pi(d_i) = \min(\pi_1(d_i), \dots, \pi_l(d_i))$$

$$\pi(d_i) = \pi_1(d_i) \cdot \dots \cdot \pi_l(d_i)$$

Combinaison disjonctive \vee L'opérateur disjonctif est particulièrement utile pour combiner des informations conflictuelles, c'est à dire lorsque les sources sont discordantes. Un opérateur est disjonctif, lorsque c'est un opérateur d'union, comme le maximum ou la somme. Le résultat de la combinaison sera proche de 1 si et si une des valeurs à combiner au moins est proche de 1.

$$\pi(d_i) = \max(\pi_1(d_i), \dots, \pi_l(d_i))$$

$$\pi(d_i) = \pi_1(d_i) + \dots + \pi_l(d_i)$$

Combinaison de compromis Certains opérateurs sont dits de compromis, c'est à dire qu'ils sont bien adaptés aux problèmes de combinaison un peu conflictuels : lorsqu'il y a du conflit mais qu'il n'est pas total. C'est le cas des opérateurs de médiane ou de moyenne.

Combinaison adaptative Une règle s'adaptant au conflit existant entre les sources a été proposée par Dubois et Prade [22]. Pour simplifier la définition de cet opérateur, regardons le résultat concernant la combinaison adaptative de seulement deux distributions de possibilités π_1, π_2 . Cet opérateur passe par le calcul du degré de compatibilité h , c'est à dire l'importance de recouvrement des fonctions : c'est un indice de conflit.

$$h(\pi_1, \pi_2) = \max_{d_i \in \Omega} \min(\pi_1(d_i), \pi_2(d_i))$$

Ensuite l'opérateur de combinaison est défini par :

$$\begin{cases} \pi = \max\left(\frac{\pi_1 \wedge \pi_2}{h(\pi_1, \pi_2)}, \min(1 - h(\pi_1, \pi_2), \pi_1 \vee \pi_2)\right) & \text{si } h(\pi_1, \pi_2) > 0 \\ \pi = \pi_1 \vee \pi_2 & \text{sinon} \end{cases}$$

Remarque. 2 Si les observations sont concordantes ou, en tous cas, si le conflit est faible, il est légitime d'utiliser un opérateur conjonctif de combinaison, alors que dès que le conflit devient important, les sources étant alors discordantes, l'opérateur utilisé doit être disjonctif. Les règles de combinaison auto adaptatives sont justifiées. De plus, le changement d'une règle à une autre est progressif ce qui évite toutes discontinuités.

Exemple : Si on reprend l'exemple précédent, on obtient pour la combinaison adaptative suivante :

$$\begin{aligned} h(\pi_1, \pi_2) &= \max(\min(\pi_1(C), \pi_2(C)), \min(\pi_1(\overline{C}), \pi_2(\overline{C}))) \\ &= \max(\min(0.8, 0.3), \min(0.6, 0.9)) = \max(0.3, 0.6) = 0.6 \end{aligned}$$

On choisit l'opérateur conjonctif minimum et disjonctif maximum :

$$\begin{aligned} \pi_1(C) &= 0.8, \pi_1(\overline{C}) = 0.6 \\ \pi_2(C) &= 0.3, \pi_2(\overline{C}) = 0.9 \end{aligned}$$

$$\begin{cases} \pi_1 \wedge \pi_2(C) = \min(0.8, 0.3) = 0.3 \\ \pi_1 \wedge \pi_2(\overline{C}) = \min(0.6, 0.9) = 0.6 \end{cases}$$

$$\begin{cases} \pi_1 \vee \pi_2(C) = \max(0.8, 0.3) = 0.8 \\ \pi_1 \vee \pi_2(\overline{C}) = \max(0.6, 0.9) = 0.9 \end{cases}$$

$$\begin{aligned} \pi(C) &= \max\left(\frac{\pi_1 \wedge \pi_2(C)}{h(\pi_1, \pi_2)}, \min(1 - h(\pi_1, \pi_2), \pi_1 \vee \pi_2(C))\right) \\ &= \max\left(\frac{0.3}{0.6}, \min(0.4, 0.8)\right) = \max(0.5, 0.4) = 0.5 \end{aligned}$$

$$\begin{aligned} \pi(\overline{C}) &= \max\left(\frac{\pi_1 \wedge \pi_2(\overline{C})}{h(\pi_1, \pi_2)}, \min(1 - h(\pi_1, \pi_2), \pi_1 \vee \pi_2(\overline{C}))\right) \\ &= \max\left(\frac{0.6}{0.6}, \min(0.4, 0.9)\right) = \max(1, 0.4) = 1 \end{aligned}$$

2.3.5.6 Décision

Différents critères de décision peuvent être utilisés dans la théorie des ensembles flous. Le plus courant est le critère de maximum du degré d'appartenance. La décision choisie est celle qui maximise le degré d'appartenance selon l'ensemble des sources. La décision d_i est prise si $\mu_i(x) = \max \{\mu_k(x), 1 \leq k \leq n\}$.

Concernant la théorie des possibilités, les critères de maximum de nécessité ou de maximum de possibilité peuvent être aussi utilisés.

Exemple : La décision pour l'exemple précédent correspond à l'évènement C "il y a une cible présente" car $\pi(\overline{C}) > \pi(C)$

2.3.5.7 Limites et intérêts

Cette approche permet de représenter les imprécision et les incertitudes de l'information. Elle permet de combiner des informations très variées grâce à la richesse et à la souplesse des opérateurs proposés, elle permet ainsi d'utiliser des informations sémantiques ou d'expertise. L'inconvénient de cette méthode est la nécessité d'une expertise sur les données pour régler les paramètres.

2.3.6 Comparaison

Nous avons présenté les principes des différentes théories majoritairement utilisées dans le cadre de systèmes de fusion : la théorie des probabilités, la théorie des croyances, et la théorie des possibilités. Une description plus complète de ces outils est donnée dans l'ouvrage [54]. Les différences majeures entre ces théories résident dans leur modélisation de l'imperfection des données et donc dans les différentes manières de les combiner. Le but n'a pas été de désigner une méthode supérieure à une autre, mais de montrer la complémentarité de leur représentation de l'incertain. En général, le problème à traiter permet de définir la meilleure théorie à utiliser (voir Table 2.9). Dans le cadre de notre application, nous avons uniquement utilisé la théorie probabiliste car la plupart des algorithmes de suivi de cibles utilisent ce formalisme et que nous souhaitons une certaine cohérence en restant dans le formalisme bayésien pour le pistage et pour la prise de décision. De plus, la mise en place et l'utilisation de la théorie probabiliste est plus simple et elle est a priori suffisante pour prendre en compte les différentes imperfections rencontrées.

	Probabilités	Croyances	Possibilités
Origine	Bayes (1774)	Dempster (1974)	Zadeh (1965)
Incertitude	oui	oui	oui
Absence de connaissance	non, $P(w_{1,2}) = 0.5$	oui, $m(w_1 \cup w_2) = 1$	oui, $\mu_{1,2} = 1$
Opérateur de fusion	Bayes	\odot, \oslash	\wedge, \vee
Opérateur de Décision	maximum a posteriori	Transformation pignistique	Max de possibilité, nécessité...
Contraintes	$P(A) = \sum_{w \in A} P(w)$ $P(\emptyset) = 0$ $P(\Omega) = 1$	$\sum_{A \in D} m_j(A) = 1$	$\sup \{\pi(A), A \in \Omega\} = 1$
Variable Discrète	oui	oui	oui
Variable Continue	oui	non	oui
Avantages	Cadre math puissant Statistique Apprentissage	Ignorance représentée conflit mesuré	Représentation langage naturel

TABLE 2.9 – Avantages et inconvénients des différentes théories.

Chapitre 3

État de l’art : Pistage multi-cibles

Sommaire

3.1	Notations	54
3.2	Problème d’estimation	54
3.3	Problématique du pistage multi-cibles	58
3.4	Méthode du plus proche voisin	60
3.5	Probabilistic Data Association (PDA)	63
3.6	Joint Probabilistic Data Association (JPDA)	65
3.7	Multiple Hypothesis Tracker (MHT)	67
3.8	Probability Hypothesis Density (PHD)	72
3.9	Cardinalized Probability Hypothesis Density (CPHD)	75
3.10	Implémentations possibles des filtres PHD et CPHD	78
3.11	Gaussian Mixture Cardinalized Probability Hypothesis Density (GMCPHD)	79
3.12	Comparaison de filtres	89

3.1 Notations

Notation	Signification
$A_{k k-1}$	Variable A a priori de l'instant k
$A_{k k}$	Variable A a posteriori de l'instant k
$\hat{x}_{k k}$	Moyenne de l'estimation du vecteur d'état
$P_{k k}$	Matrice de covariance de l'estimation du vecteur d'état
z	mesure ou observation

TABLE 3.1 – Notations générales utilisées dans ce Chapitre

3.2 Problème d'estimation

3.2.1 Notations

Notation	Signification
k	Numéro d'acquisition
X_k	Variable d'état du système à l'instant k
U_{k-1}	Entrées connues du système
V_{k-1}	Bruit sur l'estimation des variables d'état
Z_k	Mesures ou Observations
W_k	Bruit de mesure
f	Fonction d'évolution
h	Fonction d'observation
F_k	Matrice de transition
B_k	Matrice d'entrée
T_e	Période d'échantillonnage
I_d	Matrice Identité
H	Matrice d'observation
R_k	Matrice de covariance du bruit de mesure
Q_k	Matrice de covariance du bruit de modèle
P_D	Probabilité de détection
β_{fa}	densité de fausses alarmes

TABLE 3.2 – Notations utilisées pour les problème d'estimation

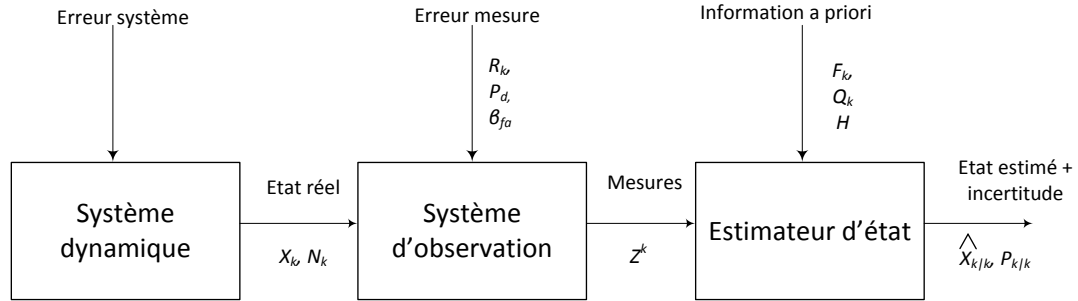


FIGURE 3.1 – Problème d'estimation

3.2.2 Introduction

Dans ce chapitre le problème d'estimation correspond au problème d'estimation de l'état d'un système.

Un problème d'estimation peut être représenté par la figure 3.1. A chaque itération k , l'objectif est d'estimer au mieux l'état réel du système X_k , de taille variable N_k , à partir de l'ensemble des mesures Z^k .

Les mesures ne correspondent pas parfaitement à l'état réel du système, ces erreurs ou ces différences sont dues à certains paramètres que l'on suppose connus (R_k, P_D, β_{fa}). Les variables F_k, Q_k, H caractérisent le modèle de description du système, elles sont également connues et dépendent du choix de modèle effectué.

Un système dynamique observable peut se décrire par deux équations :

- une équation d'état $X_k = f(X_{k-1}, U_{k-1}, V_{k-1})$

f est la fonction d'évolution (elle peut être linéaire ou non), X_{k-1}, X_k sont les variables d'état du système à l'instant $k-1$ et k , elles correspondent aux données que nous souhaitons connaître (distance du mobile, vitesse...), U_{k-1} sont les entrées connues du système et V_{k-1} est le bruit sur l'estimation des variables d'état. Ce processus est un processus markovien du premier ordre, c'est à dire que la variable aléatoire d'état à l'instant k ne dépend que de l'état précédent.

- une équation d'observation $Z_k = h(X_k, w_k)$

h est la fonction de d'observation (elle peut être linéaire ou non), Z_k sont les mesures ou observations, et w_k est le bruit de mesure.

En général, on essaie de se ramener à un processus linéaire pour la description du système.

Cette description est souvent naturellement continue :

$$\begin{cases} \dot{X}(t) = F_c X(t) + B_c u(t) + M_c w(t) \\ Z(t) = H X(t) + N v(t) \end{cases}$$

Ces équations peuvent être discrétisées, on a alors les équations discrètes d'un système linéaire :

$$\begin{cases} \dot{X}_{k+1} = F X_k + B u_k + w_k \\ Z_k = H X_k + v_k \end{cases}$$

avec F étant la matrice de transition discrète et B la matrice d'entrée. H_k est la matrice d'observation qui permet de définir les composantes du vecteur d'état qui sont observées grâce à Z_k . v_k est le bruit associé au capteur de mesure, w_k est le bruit du modèle.

$$F = \exp(F_c T_e)$$

La matrice de transition peut s'obtenir grâce au développement de Taylor de la fonction $F(t) = \exp(F_c t)$ (fonction qui correspond au résultat de l'équation différentielle précédente). Cette approche peut conduire à de grosses imprécisions, il existe ainsi d'autres approches permettant d'approcher $F(T_e) = \exp(F_c T_e)$, lorsque F_c est définie, cette valeur peut se calculer aussi explicitement.

$$F(t) = I_d + F_c t + \frac{(F_c t)^2}{2!} + \dots \quad (3.1)$$

Nous pouvons obtenir donc la matrice de transition $F = F(T_e)$ discrète en limitant le développement de Taylor en première approximation (mais il existe des solutions exactes).

$$F = F(T_e) \simeq I_d + F_c T_e \quad (3.2)$$

T_e étant la période d'échantillonnage et I_d est la matrice identité.

De même B est définie par :

$$B = T_e B_c$$

Le bruit de modèle permet de rendre compte des incertitudes concernant le modèle. Soit Q_c la matrice de covariance du bruit blanc $w(t)$, matrice symétrique définie positive. La

matrice de covariance du bruit de modèle discrète est :

$$Q_k = \int_0^{T_s} F_k M_c Q_c M_c^T F_k^T dt \quad (3.3)$$

Exemple : Calcul d'une matrice de transition discrète dans le cas d'un mobile se déplaçant sur 1 dimension. Nous nous intéressons à la distance du mobile et à sa vitesse (sur un seul axe), c'est à dire $X = (distance, vitesse)^T$. Nous utilisons un modèle sans entrée u , avec un bruit de modèle. L'équation décrivant l'évolution du système est donc :

$$\dot{X} = \begin{pmatrix} \dot{distance} \\ \dot{vitesse} \end{pmatrix} + B_c u(t) = \underbrace{\begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix}}_{F_c} X + w \quad (3.4)$$

$$F(t) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \begin{pmatrix} 0 & t \\ 0 & 0 \end{pmatrix} + \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} 1 & t \\ 0 & 1 \end{pmatrix} \quad (3.5)$$

$$F = F(T_e) = \begin{pmatrix} 1 & T_e \\ 0 & 1 \end{pmatrix} \quad (3.6)$$

où $w \sim N(0, Q_k)$ est un bruit gaussien de moyenne nulle avec la matrice de covariance Q_k .

$$Q_c = \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix} \quad (3.7)$$

$$Q_k = \int_0^{T_s} \begin{pmatrix} 1 & Ts \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ Ts & 1 \end{pmatrix} dt = \int_0^{T_s} \begin{pmatrix} Ts^2 & Ts \\ Ts & 1 \end{pmatrix} dt \quad (3.8)$$

$$Q_k = \begin{pmatrix} \frac{Ts^3}{3} & \frac{Ts^2}{2} \\ \frac{Ts^2}{2} & Ts \end{pmatrix} \quad (3.9)$$

Dans le cas d'un système linéaire et gaussien, le filtre Kalman est une solution explicite du problème d'estimation.




FIGURE 3.2 – Exemple de scénario problématique d’association mesures/cible

3.3 Problématique du pistage multi-cibles

3.3.1 Introduction

Les systèmes de pistage sont des filtres d’estimateur d’état, ils ont pour but de localiser un objet. Dans la littérature, la plupart des systèmes de pistage, dits “tracking”, sont surtout utilisés pour estimer la localisation d’un objet, sa position, sa vitesse...

Le multi pistage (ou tracking) consiste à estimer l’état d’un ensemble de cibles à chaque instant. Le problème d’estimation est donc double et nécessite l’estimation la plus précise possible de l’état des cibles ainsi que l’estimation du nombre de cibles (en gérant la naissance et la mort de celles-ci). La taille de l’ensemble des mesures à chaque instant varie également, car les cibles peuvent être non détectées (non détection) et des mesures peuvent être associées à aucune cible (fausse alarme). Une des problématiques du multi tracking est donc l’association correcte des mesures aux cibles.

La figure 3.2 est un exemple typique du problème d’association entre les mesures et les cibles. Cette figure représente l’historique de l’estimation de l’état de deux cibles ($T_{k,i}$) par le système ainsi que la représentation de la prédiction de leur état à l’instant k (leur moyenne est notée $\hat{x}_{k|k-1,i}$ et leur covariance correspond à l’ellipse représentée autour de l’état prédit). Trois mesures sont disponibles à l’instant k pour ces deux cibles, il revient donc au système de pistage multi cibles d’associer correctement les mesures et les cibles.

3.3.2 Différentes approches

Cette problématique peut être considérée de deux points de vue différents. Sachant que l'espace d'état est continu :

- Soit on discrétise en premier lieu l'espace d'état, on considère alors l'évolution et l'état de chaque cible individuellement. Ces approches ont un point de vue plus local et sont donc plus facilement personnalisables en fonction des cibles.
- Soit on peut considérer l'évolution et le pistage de l'ensemble des cibles. L'ensemble des cibles est alors vu comme une variable multimodale, on discrétise en dernier lieu pour obtenir une information particulière à chaque cible. Ces approches ont un point de vue plus global de la situation observée.

Dans la suite de ce chapitre, nous allons présenter différentes méthodes de pistage multi cible. Tout d'abord des méthodes adoptant le premier point de vue, considérant chaque cible individuellement, les méthodes du plus proche voisin basées sur le filtre de Kalman, le MHT (Multiple Hypothesis Tracker) et les filtres descendant du PDAF (Probabilistic Data Association Filter). Ensuite nous verrons quelques filtres adoptant le second point de vue. Ces filtres sont basés sur une modélisation de l'ensemble des cibles par un ensemble fini de variables aléatoires (RFS= Random Finite Set) : le PHD et le CPHD.

Pour conclure ce chapitre, une comparaison de ces filtres sera effectuée sans aucun a priori d'application.

3.4 Méthode du plus proche voisin

La méthode du plus proche voisin (nearest neighbor) est le plus simple filtre de pistage multi cible utilisé dans la littérature [70]. Il est basé sur les équations du filtre de Kalman. Nous allons donc commencer par l'explication et la description du filtre de Kalman.

3.4.1 Filtrage de Kalman

La description détaillée du filtre de Kalman peut être trouvée dans [128].

Le filtre de Kalman est un filtre à réponse impulsionnelle infinie qui estime les états d'un système dynamique à partir d'une série de mesures incomplètes ou bruitées.

Le filtre de Kalman est un estimateur récursif. Cela signifie que pour estimer l'état courant, seul l'état estimé précédent et les mesures actuelles sont nécessaires. L'hypothèse markovienne d'ordre 1 est considérée.

Pour utiliser le filtre de Kalman simple, il faut que l'évolution du système et l'équation de mesure soient linéaires et qu'on puisse modéliser le vecteur d'état et les bruits (de mesure et de modèle) comme des variables aléatoires suivant des lois blanches et gaussiennes.

Le filtre de Kalman caractérise donc l'estimation de notre vecteur d'état par une gaussienne (de moyenne \hat{x}_k et de covariance P_k). Les bruits de modèle et d'observation sont blancs, gaussiens, et $w_{k-1} \sim N(0, Q_k)$ $v_{k-1} \sim N(0, R_k)$.

Les équations du filtre de Kalman se décomposent en 2 parties, l'étape de prédiction et l'étape de mise à jour :

$$\hat{x}_{k|k-1} = F_k \hat{x}_{k-1|k-1} + B_k u_{k-1} \quad (3.10)$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_{k-1} \quad (3.11)$$

Le gain de Kalman K se définit par :

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (3.12)$$

Le gain de Kalman K permet d'effectuer un compromis entre la prédiction du vecteur d'état et l'observation de ce vecteur d'état. Les notations utilisées sont les même que celles utilisées dans le paragraphe 3.2.

La mise à jour de la moyenne et de la matrice de covariance est :

$$\hat{x}_{k|k} = \hat{x}_{k-1|k-1} + K_k(z_k - H_k \hat{x}_{k|k-1}) \quad (3.13)$$

$$P_{k|k} = (Id - K_k H_k) P_{k|k-1} \quad (3.14)$$

Ainsi, si l'incertitude du vecteur d'état est grande, le gain sera grand et l'innovation sera favorisée. De même, si l'incertitude de la mesure est grande, alors la prédiction du vecteur d'état sera privilégiée.

Le filtre de Kalman est un filtre récursif qui nécessite donc une initialisation. La covariance P_k du vecteur d'état traduit la confiance qu'on a en l'estimation \hat{x}_k . Si la position initiale du vecteur d'état est connue, alors la moyenne $\hat{x}_0 = (x_{1,0} \dots x_{2,0})$ et la covariance $P_0 = 0 \times Id$. Si la position initiale du vecteur d'état est inconnue, alors on choisit une moyenne initiale nulle et une covariance infinie ou d'après [128] une valeur importante v_1 suffit pour exprimer l'incertitude initiale, $P_0 = v_1 \times Id$.

3.4.2 Associations mesures/cibles

La méthode du plus proche voisin consiste à considérer chaque cible séparément. Chaque cible évolue séparément grâce à son propre filtre de Kalman. La difficulté du filtrage multi cible revient donc à appareiller correctement une nouvelle mesure avec une précédente piste. Une piste étant un résultat précédent du filtre de pistage représentant une cible. Pour cette méthode, la piste est associée avec la mesure la plus proche (comme l'indique le nom de la méthode). Pour pouvoir prendre en compte l'imprécision, sur les mesures et sur l'estimation d'état des cibles, il est judicieux de choisir un critère de distance adapté. On peut par exemple choisir la mesure qui maximise la probabilité d'association P_{ass} d'une piste $x_{k,j}$ avec la mesure z :

$$z = \underset{z_{k,i}}{\operatorname{argmax}} \{P_{ass}(z_{k,i}, x_{k,j})\}$$

La probabilité d'association peut être calculé par :

$$P_{ass}(z_{k,i}, x_{k,j}) = \frac{1}{\sqrt{2\pi |R_{k,i} + P_{k,j}|}} \exp\left(-\frac{1}{2} (z_{k,i} - H x_{k,j})^T (R_{k,i} + P_{k,j})^{-1} (z_{k,i} - H x_{k,j})\right)$$

Cependant en cas de non détection d'une cible, celle-ci sera potentiellement associée à une mauvaise mesure. Afin de limiter ce problème, un fenêtrage statistique peut être effectué,

cette méthode est expliquée et développée dans la suite. Dans le cas d'une non détection la cible ne sera potentiellement pas associée à une mesure, et l'état est estimé comme étant l'état prédit. L'étape de correction du filtre de Kalman n'est pas effectuée.

3.4.3 Fenêtrage statistique

Pour limiter le nombre de mesures à traiter concernant le pistage d'une cible, une sélection des mesures peut être faite. Cette sélection est appelée "fenêtrage statistique" (*gating* en anglais) [94]. Pour chaque piste, le fenêtrage consiste à délimiter une zone de sélection des mesures. Cette zone est définie à partir de l'état prédit d'une cible et de sa covariance. Les mesures statistiquement éloignées de la cible sont éliminées. En pratique, et dans un cas gaussien, le test de validation d'une mesure z_k utilise la distance de Mahalanobis :

$$\begin{cases} Si \left(z_{k,i}, -\hat{x}_{k|k-1,j} \right)^T \left(P_{k|k-1,j} \right)^{-1} \left(z_{k,i}, -\hat{x}_{k|k-1,j} \right) < \gamma \text{ alors } z_{k,i} \text{ est validée} \\ Si \left(z_{k,i}, -\hat{x}_{k|k-1,j} \right)^T \left(P_{k|k-1,j} \right)^{-1} \left(z_{k,i}, -\hat{x}_{k|k-1,j} \right) > \gamma \text{ alors } z_{k,i} \text{ est rejetée} \end{cases}$$

Plus de détails sur le calcul du seuil γ sont disponibles dans [19].

Pour conclure, la méthode du plus proche voisin est la méthode la plus naturelle des filtres de pistage multi-cibles, sa simplicité de mise en œuvre est intéressante pour la plupart des applications. Cependant concernant nos données, ce filtre ne convient pas car il ne permet pas de gérer correctement les fausses alarmes ou les non détections.

D'autres filtres permettent une gestion plus évoluée des problèmes de détection, tel que le filtre PDA décrit dans le paragraphe suivant.

3.5 Probabilistic Data Association (PDA)

3.5.1 Notations

Notation	Signification
$\hat{x}_{k k,j}^i$	Estimation a posteriori de la moyenne de la gaussienne j mise à jour par la mesure i
$p_{i,j}$	probabilité d'association entre la cible j et la mesure i
P_D	Probabilité de détection
S_j	Matrice de covariance du résidu de la piste
β	somme de la densité de nouvelles pistes et de la densité de fausses alarmes
M	dimension de a mesure
$d_{i,j}$	Distance statistique normalisée entre la piste j est la mesure i
Θ_k	Ensemble des événements d'association possibles
Θ_k^a	Scénario d'association piste/mesure
w_k	Matrice d'association
N_{pa}	Nombre de pistes associés
N_{pna}	Nombre de pistes non associées
N_{mna}	Nombre de mesure non associées

TABLE 3.3 – Notations utilisées pour la méthode du PDA, JPDA

3.5.2 Description du PDA

L'approche de l'association probabiliste des données à été introduite par Bar Shalom et Tse [4] afin de résoudre les problèmes où plusieurs observations proviennent d'un même objet. Le PDA est un estimateur qui consiste à utiliser toute les observations présentes dans la fenêtre d'association pour estimer l'état de la cible.

Ainsi, l'état estimé de la cible correspond à la somme pondérée des mises à jour de l'état prédit avec les N mesures à prendre en compte :

$$\hat{x}_{k|k,j} = \sum_{i=1}^N p_{i,j} \hat{x}_{k|k,j}^i$$

où $\hat{x}_{k|k,j}^i$ correspond à la correction de l'état prédit de la cible j avec la mesure i . La valeur $p_{i,j}$ correspond à la probabilité d'association entre la cible j et la mesure i , elle est définie par :

$$p_{i,j} = \begin{cases} \frac{b}{b + \sum_{l=1}^n \alpha_{j,l}} & \text{pour } j = 0 \\ \frac{\alpha_{j,l}}{b + \sum_{l=1}^n \alpha_{j,l}} & \text{pour } 1 \leq j \leq N \end{cases}$$

avec $j = 0$ représentant le cas de non association de piste et :

$$b = (1 - P_D) \beta (2\pi)^M \sqrt{|S_j|}$$

S_j est la matrice de covariance du résidu de la piste, β est la somme de la densité de nouvelle piste et de la densité de fausses alarmes, M est la dimension de la mesure.

$$\alpha_{i,j} = P_D \exp\left(\frac{-d_{i,j}^2}{2}\right)$$

P_D est la probabilité de détection a priori, $d_{i,j}$ est la distance statistique normalisée entre la piste j et la mesure i .

De la même façon, le calcul de la matrice de covariance est modifié, pour plus de détails, voir [4].

Avec le PDA, lors d'un pistage multi cible, les autres pistes ne sont pas prises en compte. Cela pose un problème lorsque les pistes interfèrent, c'est à dire lorsque elles se croisent, où encore lorsqu'une mesure est présente dans la fenêtre de deux pistes différentes.

3.6 Joint Probabilistic Data Association (JPDA)

L'association probabiliste jointe des données a été développée afin de gérer les situations conflictuelles (lorsque deux pistes au moins se partagent un ensemble de mesures) avec une approche basée sur le PDA. Le calcul de l'état estimé et de la covariance de chaque piste est le même. Seule la définition de la probabilité de l'association de la piste j avec la mesure i est modifiée pour prendre en compte toutes les hypothèses envisageables. Soit Θ_k l'ensemble des événements d'association possibles. $\Theta_k = \{\Theta_k^a\}$, Θ_k^a est un scénario a d'association possible. On définit une matrice représentant chaque association possible par :

$$w_k = [w_{ji}(\Theta_k^a)] \quad \begin{matrix} 1 \leq i \leq m_k \\ 0 \leq j \leq N \end{matrix}$$

avec $j = 0$ correspondant au cas où la mesure est une fausse alarme. m_k est le nombre de mesure à l'instant k , N est le nombre de pistes. Concernant l'exemple de la Figure 3.2, on peut créer 7 matrices d'association (avec les hypothèses que chaque cible ne génère qu'une mesure, chaque mesure ne peut provenir que d'une cible) :

$$\begin{aligned} w_k^1 &= \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix} & w_k^3 &= \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} & w_k^5 &= \begin{pmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} \\ w_k^2 &= \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{pmatrix} & w_k^4 &= \begin{pmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{pmatrix} & w_k^6 &= \begin{pmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix} \\ & & w_k^7 &= \begin{pmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix} \end{aligned}$$

La matrice w_k^1 correspond à l'hypothèse : toutes les mesures sont des fausses alarmes. Finalement, on obtient la nouvelle définition de $p_{i,j}$:

$$p_{i,j} = \sum_{\forall \Theta_k^a \in \Theta_k} P(\Theta_k^a) w_{ji}(\Theta_k^a)$$

$$p_{i,0} = 1 - \sum_{j=1}^{m_k} p_{i,j}$$

Avec la probabilité du scénario d'association définie par :

$$P(\Theta_k^a) = \frac{P'(\Theta_k^a)}{\sum_{\forall \Theta_k^a \in \Theta_k} P'(\Theta_k^a)}$$

$$P'(\Theta_k^a) = P_D^{Npa} (1 - P_D)^{Npna} \beta^{Nmna} \prod g_{i,j}$$

P_D est la probabilité de détection a priori, β est la somme de la densité de nouvelles pistes et de la densité de fausses alarmes, Npa est le nombre de pistes associées, $Npna$ est le nombre de pistes non associées, $Nmna$ est le nombre de mesures non associées.

$$g_{i,j} = \frac{\exp\left(\frac{-d_{i,j}^2}{2}\right)}{(2\pi)^M \sqrt{|S_j|}}$$

S_j est la matrice de covariance du résidu de la piste, M est la dimension de la mesure, $d_{i,j}$ est la distance statistique normalisée entre la piste j et la mesure i .

Les filtres PDA ou JPDA sont des filtres de pistage multi-cibles intéressants car ils prennent en compte les performances de détection du capteur à travers l'utilisation de probabilité de détection et de la densité de fausses alarmes. De plus, ils peuvent gérer les cas où plusieurs mesures proviennent de la même cible. Cependant, l'estimation du nombre de pistes n'est pas effectué naturellement dans ces filtres, ces filtres sont donc particulièrement adaptés aux situations ou applications qui ont pour but de suivre un nombre connu de cibles. Dans les applications routières ciblées par notre travail, le nombre d'entités routières n'est pas connu. Certains filtres existants dans la littérature gèrent naturellement l'ensemble des problèmes particuliers à nos applications : le MHT et le CPHD présentés dans la suite.

3.7 Multiple Hypothesis Tracker (MHT)

3.7.1 Notations

Notation	Signification
P_d	Probabilité de détection
β_{fa}	Densité de fausses alarmes
β_{nt}	Densité de nouvelles pistes
$s_{k,l}$	Score de la piste l
L_{H_n}	Score de H_n
H_n	Hypothèse d'association
P_G	Probabilité globale d'une piste

TABLE 3.4 – Notations utilisées pour la méthode du MHT

3.7.2 Description du MHT

Le filtre MHT (Multiple Hypothesis Tracker) proposée par Reid en 1979 [84], est une méthode de suivi multi-cible qui analyse l'ensemble des hypothèses sur l'origine des mesures pour prendre une décision sur l'association. En effet une mesure peut être liée à :

- une fausse alarme,
- une piste réelle déjà existante dans l'historique,
- une nouvelle piste inconnue dans historique.

En effet à partir des observations du capteur, le filtre génère un arbre d'hypothèse sur l'origine de l'ensemble des mesures et la probabilité de chaque hypothèse est calculée récursivement.

Pour bien expliquer le principe de cet algorithme nous allons construire l'arbre d'hypothèses lié à l'exemple présenté sur la figure 3.2. Dans cet exemple, la mesure z_1 peut être :

- une fausse alarme, hypothèse indexée par 0,
- la continuité de la piste existante 1,
- la continuité de la piste existante 2,
- le début d'une nouvelle piste 3.

On fait l'hypothèse qu'une piste peut être associée à une ou aucune mesure. Réciproquement, une mesure est associée à une ou aucune piste. Les mesures z_2 et z_3 permettent de construire l'arbre d'hypothèses présenté en Figure 3.3. Par exemple la dernière colonne de cet arbre représente l'hypothèse d'association où toutes les mesures correspondent à des fausses alarmes.

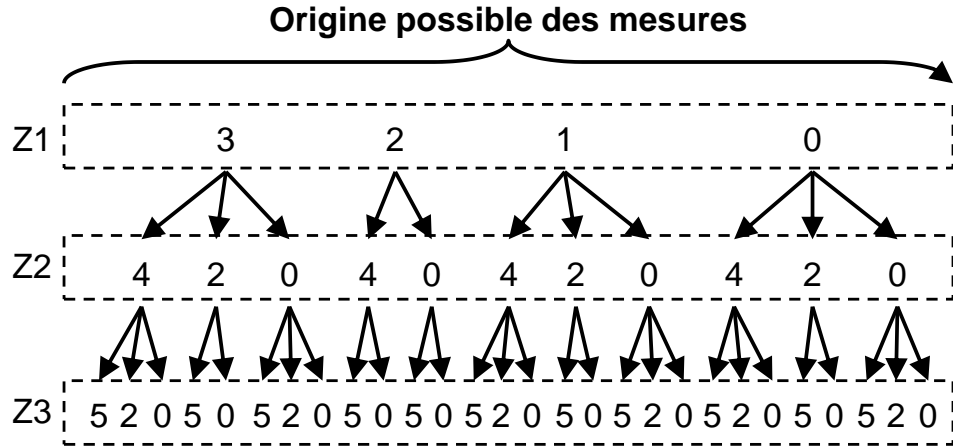


FIGURE 3.3 – Arbre représentant l'ensemble des associations possibles

Cet arbre, représentant les différents scénarios d'associations, est ensuite étendu et complété à l'instant $k + 1$ en générant de nouvelles hypothèses. On s'aperçoit donc que la taille de cet arbre croît de façon exponentielle. L'enjeu principal du MHT est de donc de pouvoir réduire le nombre d'hypothèses à chaque instant. Une des approches proposées, afin de résoudre le problème du nombre trop important d'hypothèses, est une approche orientée piste, le TOMHT (Track oriented multiple hypothesis tracker).

3.7.3 TOMHT

Dans le MHT, même en éliminant les hypothèses d'association les moins probables, le problème du trop grand nombre d'hypothèses persiste. C'est pour cela que certains auteurs [5] ont décidé de réduire encore le nombre d'hypothèses en effectuant une première sélection sur les pistes elles-mêmes avant la construction de l'arbre d'association. On classe donc chaque piste en fonction de son "score". Ce score est calculé de façon récursive à partir de la vraisemblance des mesures à la piste. L'algorithme TOMHT est composé de différentes étapes que nous allons décrire dans la suite.

3.7.3.1 Formation et gestion des pistes

Tout d'abord le score de chaque piste est calculé itérativement en fonction des vraisemblances des mesures à chaque piste. Pour chaque piste existante, on effectue un fenêtrage statistique. D'après Blackman [5], le score de chaque nouvelle piste ainsi construite se calcule récursivement à partir du logarithme népérien du ratio de vraisemblance de la mesure $z_{j,k}$ et

du score de la piste à l'itération $k - 1$.

$$g(z_{j,k}|T_{k,l}) = \ln \left(\frac{P_d}{\beta_{fa} + \beta_{nt}} \cdot \frac{e^{-0.5 \cdot (z_{j,k} - H \cdot x_{k|k-1})^T (H \cdot P_{k|k-1} \cdot H^T)^{-1} (z_{j,k} - H \cdot x_{k|k-1})}}{\sqrt{2 \cdot \pi |H \cdot P_{k|k-1} \cdot H^T|}} \right) \quad (3.15)$$

$$s_{k,l} = g(z_{j,k}|T_{k,l}) + s_{k-1,l} \quad (3.16)$$

Pour chaque piste de l'instant $k - 1$, on observe aussi la nouvelle piste résultant d'une non détection de la mesure associée à cette piste. Dans ce cas le calcul du score correspond à :

$$s_{k,l} = s_{k-1,l} + \ln(1 - P_d) \quad (3.17)$$

Concrètement, le score est calculé de façon itérative sur un nombre N d'anciennes vraisemblances.

$$s_{k,l} = g(z_{j,k}|T_{k,l}) + \sum_{i=1}^N g(z_i|T_{i,l}) \quad (3.18)$$

Chaque piste est ensuite confirmée, non confirmée ou supprimée selon le score obtenu. En effet, dans l'approche de Demos [17], la classification des pistes repose sur un test séquentiel basé sur le ratio des probabilités appelé test de Wald [118]. Si le score est inférieur à un certain seuil U_1 , la piste est alors supprimée. Si le score de la piste est supérieur à un certain seuil U_2 , la piste est confirmée, et si le score est compris entre ces deux seuils, alors la piste est non confirmée.

Il faut qu'une piste soit d'abord confirmée avant d'être supprimée, on ne peut pas supprimer une piste qui n'existait pas. Les pistes confirmées et non confirmées seront donc traitées dans les étapes du filtre suivantes.

3.7.3.2 Clustering

Une méthode de clustering consiste à rassembler toutes les pistes qui interagissent entre elles, c'est à dire les pistes qui ont au moins une mesure en commun par le fenêtrage statistique. Par exemple si une mesure se trouve suffisamment proche de la piste 1 et de la piste 2 à l'instant k , et qu'une autre mesure se trouve proche de la piste 2 et de la piste 3 à l'instant $k + 1$, le cluster rassemblera les pistes 1, 2, et 3. Cette étape permet également de limiter la taille des arbres d'association à traiter, en effet, chaque cluster est ensuite traité totalement

indépendamment des autres clusters.

3.7.3.3 Formation des hypothèses

Pour chaque cluster, l'algorithme construit l'arbre d'association pour les pistes prédites et aux mesures de chaque cluster. Ensuite la probabilité de chaque hypothèse d'association est calculée. Tout d'abord le score d'une hypothèse d'association L_{H_n} correspond à la somme des scores des pistes prédites associées à cette hypothèse

$$L_{H_n} = \sum_{T^{k,l} \in H_n} s_{k,l} \quad (3.19)$$

A partir de la formule des probabilités totales, on calcule la probabilité de cette hypothèse en fonction des L autres hypothèses possibles.

$$P(H_n|Z^k) = \frac{\exp(L_{H_n})}{1 + \sum_{n=1}^L \exp(L_{H_n})} \quad (3.20)$$

Une sélection est alors faite sur les hypothèses les plus probables, et est ensuite utilisée pour calculer la probabilité de chaque nouvelle piste produite par une piste prédite de l'instant précédent $k - 1$ et d'une mesure de l'instant k .

3.7.3.4 Évaluation globale d'une piste

La probabilité globale d'une piste $P_G(T^{l,k}|Z^k)$ est ainsi calculée à partir des probabilités des hypothèses d'association utilisant cette piste.

$$P_G(T^{l,k}|Z^k) = \sum_{j=1}^J P(T^{l,k}|H_j) \cdot P(H_j|Z^k) \quad (3.21)$$

Le terme $P(T^{l,k}|H_j)$ décrit l'appartenance ou non de la piste à l'hypothèse d'association. $P(T^{l,k}|H_j) = 1$ si la piste $T^{l,k}$ participe à l'hypothèse H_j et $P(T^{l,k}|H_j) = 0$ sinon.

De la même manière que pour les hypothèses d'association, les pistes dont la probabilité est trop faible sont éliminées, les autres sont utilisées par l'algorithme pour l'étape suivante.

3.7.3.5 Estimation et merging

On prédit l'état de chaque piste survivante ainsi que leur covariance. Ces pistes prédites sont ensuite combinées pour réduire leur nombre. En effet les pistes qui se ressemblent suffisamment sont mélangées pour former une seule piste. Deux pistes se ressemblent si leurs

états estimés sont proches, c'est à dire, lorsque la distance de Malahanobis entre ces deux état est inférieur à un seuil.

On reprend alors la technique de merging expliquée dans le paragraphe 3.11.7.

Les filtres de pistage présentés précédemment utilisent tous une méthode de gestion de cible individuelle. Nous allons dans la suite présenter et introduire des filtres ayant une approche différente, plus globale, basée sur une modélisation des ensembles de cardinalité inconnue RFS (Random finite set).

3.8 Probability Hypothesis Density (PHD)

3.8.1 Notations

Notation	Signification
X_k	RFS de cibles à estimer
$S_{k k-1}$	RFS de cibles survivantes
ζ	État précédent
$B_{k k-1}$	RFS des cibles non résolues
σ_k	RFS des cibles naissantes
Z_k	RFS de mesures
$\tilde{Z}_k(x)$	RFS des mesures issues de la cible x
K_k	RFS des fausses alarmes
$v_{k k}$	fonction d'intensité a posteriori des cibles
$v_{k k-1}$	Fonction d'intensité a priori des cibles
b	fonction d'intensité des cibles naissantes
$f(x_i \zeta)$	Fonction de transition d'une cible connaissant son état précédent
P_s	Probabilité de survie
$g(z x_i)$	Vraisemblance de la mesure z connaissant l'état de la cible x_i
P_d	Probabilité de détection
$\kappa_k(z_s)$	Fonction d'intensité du bruit

TABLE 3.5 – Notations générales utilisées pour les filtres basé sur des RFS, le PHD et le CPHD

3.8.2 Ensemble Fini Aléatoire

Le PHD (Probability Hypothesis Density) est un filtre de pistage basé sur une modélisation de RFS. Nous allons tous d'abord expliquer la modélisation choisie puis les équations et le principe de ce filtre.

Un ensemble fini aléatoire (ou Random Finite Set (RFS)) est un ensemble fini de variables aléatoires continues dont la cardinalité est aussi une variable aléatoire. Notre ensemble de cibles à estimer X_k est modélisé comme un RFS, il est défini à partir du RFS des cibles survivantes $S_{k|k-1}(\zeta)$ issues des états précédents ζ , du RFS des cibles non résolues $B_{k|k-1}(\zeta)$ issus des états précédents ζ et à partir du RFS σ_k des cibles naissantes.

$$X_k = \left[\bigcup_{\zeta \in X_{k-1}} S_{k|k-1}(\zeta) \right] \cup \left[\bigcup_{\zeta \in X_{k-1}} B_{k|k-1}(\zeta) \right] \cup \sigma_k \quad (3.22)$$

De la même façon, notre ensemble de mesures Z_k peut être modélisé comme un RFS défini à partir des RFS $\tilde{Z}_k(x)$ des mesures issues des cibles x et à partir du RFS des fausses alarmes K_k .

$$Z_k = \left[\bigcup_{x \in X_k} \tilde{Z}_k(x) \right] \cup K_k \quad (3.23)$$

3.8.3 Équations du filtre

Malher [55] définit le PHD, appelé aussi fonction d'intensité, comme étant le moment du premier ordre de la densité jointe d'un ensemble de cibles a posteriori. Le PHD d'un RFS X défini sur l'espace géométrique χ est une fonction non négative v qui a la propriété suivante :

$$\forall V \subseteq \chi, E[|X \cap V|] = \int_V v(x) dx \quad (3.24)$$

$|X \cap V|$ représente le nombre de cibles sur l'espace V et $v(x)$ la fonction d'intensité en un point x .

La fonction d'intensité a priori $v_{k|k-1}$ peut s'exprimer à partir de la fonction d'intensité a posteriori de l'instant précédent :

$$v_{k|k-1}(x_i) = b(x_i) + \int f(x_i|\zeta) P_s(\zeta) v_{k-1|k-1}(\zeta) d\zeta \quad (3.25)$$

$P_s(\zeta)$ est la probabilité de survie d'une cible ayant l'état précédent ζ , $f(x_i|\zeta)$ est la fonction de transition d'une cible connaissant son état précédent, et $b(x_i)$ est la fonction d'intensité de naissance des nouvelles cibles.

La fonction d'intensité a posteriori $v_{k|k}$ quant à elle peut s'exprimer à partir de la fonction d'intensité a priori et des mesures de l'instant k Z_k

L'équation de mise à jour est donc :

$$v_{k|k}(x_i) = v_{k|k-1}(x_i) \left[(1 - P_d(x_i)) + \sum_{z \in Z_k} \frac{P_d(x_i) g(z|x_i)}{\kappa_k(z) + \int P_d(\gamma) g(z|\gamma) v_{k|k}(\gamma) d\gamma} \right] \quad (3.26)$$

$P_d(x_i)$ est la probabilité de détecter une cible à l'état x_i , $g(z|x_i)$ est la vraisemblance d'une mesure z connaissant l'état de la cible x_i , $\kappa_k(z)$ est la fonction d'intensité du bruit. Celle-ci est supposée uniforme sur χ .

Cette définition de la fonction d'intensité a posteriori permet de résoudre le problème d'association entre les mesures et les cibles grâce à l'utilisation des fonctions de vraisemblance pour chaque mesure connaissant tous les états des cibles.

Cette représentation permet de modéliser la densité de probabilité jointe de l'ensemble fini aléatoire des cibles en prenant en compte les non-détections et les fausses alarmes. L'avantage majeur de cette approche est qu'une cible n'est pas formellement associée à une ou plusieurs mesures : le problème d'association des données est donc sans objet.

Le problème principal est la mort prématurée des cibles lors d'une non détection. Examinons le cas simple d'une cible qui n'est pas détectée à l'instant k . L'équation de mise à jour de sa probabilité d'existence sera :

$$v_{k|k}(x_i) = v_{k|k-1}(x_i)(1 - P_d) \quad (3.27)$$

Avec $P_d = 0.9$ et $P_s = 0.8$, supposons que la probabilité précédente soit de 1, alors $v_{k|k-1} = 0.8$ (P_s) et la probabilité à l'instant k sera $v_{k|k} = 0.08$.

Le filtre PHD a donc peu de mémoire, alors qu'on pourrait espérer une plus petite diminution du nombre de cibles lorsqu'une non détection se produit. Pour pallier à ce problème, Malher introduit la prise en compte du nombre de cibles dans la propagation de la probabilité d'existence des cibles [56, 57].

3.9 Cardinalized Probability Hypothesis Density (CPHD)

3.9.1 Notations

Notation	Signification
$p_{k k-1}(n)$	La probabilité a priori d'avoir n cibles
$p_{k k}(n)$	La probabilité a posteriori d'avoir n cibles
$P_{\Gamma}(n)$	La probabilité d'avoir n cibles naissante
C_j^l	Le nombre de combinaison de j élément parmi l
P_s	La probabilité de survie
$\langle a, b \rangle$	le produit scalaire des variable a et b
$a!$	Factorielle de a
$p_c(n)$	La probabilité d'avoir n fausses alarmes
$e_j(Z)$	La fonction élémentaire symétrique d'ordre j de l'ensemble Z
$g(z x)$	Vraisemblance de z par rapport a l'état x
$c_k(z)$	Densité de fausses alarmes

TABLE 3.6 – Notations supplémentaires utilisées pour le CPHD

3.9.2 Description du CPHD

Le filtre Cardinalized Probability Hypothesis Density a été proposé pour la première fois par Ronald Mahler [56, 57] suite à un article écrit par Erdinc [26] qui émet l'hypothèse que les faiblesses d'estimation du nombre de cibles du filtre PHD étaient dues à l'utilisation uniquement du moment du premier ordre de la densité de probabilité jointe.

L'idée générale du CPHD est donc de propager conjointement à la fonction d'intensité v_k , l'incertitude sur l'estimation du nombre de cibles présentes sur la zone d'observation (i.e. la distribution de probabilité du nombre de cibles).

La propagation du nombre de cibles pour le filtre CPHD s'effectue avec les équations de mise à jour, l'équation de prédiction de la fonction d'intensité est donc identique à celle du filtre PHD

$$v_{k|k-1}(x_i) = b(x_i) + \left(\int f(x_i|\gamma) P_s(\gamma) v_{k-1|k-1} d\gamma \right) \quad (3.28)$$

γ décrit un état de cible précédent. La probabilité a priori d'avoir n cibles à l'instant k est calculée à partir de la fonction d'intensité a posteriori et de la probabilité a posteriori du nombre de cibles :

$$p_{k|k-1}(n) = \sum_{j=0}^n P_{\Gamma}(n-j) \sum_{l=j}^{\infty} C_j^l \frac{\langle P_s, v_{k|k-1} \rangle^j (1 - \langle P_s, v_{k|k-1} \rangle)^{l-j}}{\langle 1, v_{k|k-1} \rangle^l} p_{k-1|k-1}(l) \quad (3.29)$$

$P_{\Gamma}(n-j)$ est la probabilité d'avoir $(n-j)$ cibles naissantes. Cette définition de la probabilité du nombre de cibles est obtenue en appliquant le théorème de la probabilité totale pour chacune des hypothèses : sachant qu'il y a $(n-j)$ nouvelles cibles à l'instant k et sachant qu'il y avait l cibles à l'instant $(k-1)$, chaque hypothèse identifie $(l-j)$ cibles mortes parmi les l anciennes cibles et toutes ces hypothèses sont équiprobables. L'opérateur $\langle \cdot, \cdot \rangle$ est le produit scalaire de deux fonctions continues.

$$\langle a, b \rangle = \int a(x)b(x)dx \quad (3.30)$$

Comme pour le filtre PHD, la fonction d'intensité a posteriori $v_{k|k-1}$ peut s'exprimer à partir de la fonction d'intensité a priori et des mesures de l'instant k Z_k , mais utilise aussi la probabilité du nombre de cibles a priori.

Les équations de mise à jour sont donc :

$$\left\{ \begin{array}{l} v_{k|k}(x_i) = \frac{\langle \Psi_k^1[v_{k|k-1}, Z_k], p_{k|k-1} \rangle}{\langle \Psi_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle} (1 - P_d) v_{k|k-1}(x_i) \times \Lambda \\ \Lambda = \sum_{z \in Z_k} \frac{\langle \Psi_k^1[v_{k|k-1}, Z_k \setminus z], p_{k|k-1} \rangle}{\langle \Psi_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle} \psi(x) v_{k|k-1}(x_i) \\ p_{k|k-1}(n) = \frac{\Psi_k^1[v_{k|k-1}, Z_k](n) \cdot p_{k|k-1}(n)}{\langle \Psi_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle} \end{array} \right.$$

$\Psi_k^1[v_{k|k-1}, Z_k](n)$ est la vraisemblance des mesures Z_k par rapport à $v_{k|k-1}$ qu'il y ait n cibles, et $\langle \Psi_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle$ est un terme de normalisation.

$$\Psi_k^1[v, Z](n) = \sum_{j=0}^{\min(|Z_k|, n)} (|Z_k| - j)! p_c(|Z_k| - j) \left[\frac{n!}{(n - (j + u))!} \frac{\langle 1 - P_d, v \rangle^{n-(j+u)}}{\langle 1, v \rangle^n} \right] e_j(\Xi(v, Z_k)) \quad (3.31)$$

L'expression de la vraisemblance se calcule à partir de toutes les hypothèses possibles pour une mesure sachant qu'une mesure peut être, soit issue d'une cible, soit une fausse alarme. $p_c(|Z_k| - j)$ est la probabilité d'avoir $(|Z_k| - j)$ fausses alarmes, $|Z_k|$ étant le cardinal de l'ensemble des mesures Z_k . $e_j(\Xi(v, Z_k))$ est la fonction symétrique élémentaire de l'ensemble $\Xi(v, Z_k)$. Elle se calcule comme ceci :

$$e_j(Z) = \sum_{S \subseteq Z, |S|=j} \prod_{z \in S} z \quad (3.32)$$

$$\Xi(v, Z_k) = \{ \langle v, \psi_{k,z} \rangle, z \in Z_k \} \quad (3.33)$$

L'ensemble $\Xi(v, Z_k)$ se définit à partir de la fonction d'intensité et de la vraisemblance de chaque mesure par rapport aux états prédits des cibles $\psi_{k,z}$.

$$\psi_{k,z}(x) = \frac{g(z|x)P_d}{c_k(z)} \quad (3.34)$$

$g(z|x)$ étant la vraisemblance de z par rapport à l'état x et $c_k(z)$ est la densité de fausses alarmes.

Pour conclure, le filtre CPHD permet de gérer explicitement les problèmes de détection (non détections, fausses alarmes), le bruit affectant les mesures, ainsi que la naissance et la mort des cibles, ce qui en fait un filtre pertinent pour notre utilisation.

3.10 Implémentations possibles des filtres PHD et CPHD

En raison de l'utilisation de plusieurs intégrales dans les équations du filtre CPHD, ou du filtre PHD, il n'existe pas de forme littérale pour représenter la fonction d'intensité a posteriori. Différentes implémentations de ce filtre sont disponibles, certaines utilisant une méthode particulière PPHD ou encore une méthode de Monte Carlo avec le PHD [115, 11, 123] ou le CPHD[85, 88]. Plus de détails sur les approches de filtrage particulière peuvent se trouver dans le mémoire de thèse d'Evangelina Pollard [82].

Une deuxième version implémentable de ces filtres utilise un mélange de gaussiennes. Ces filtres modélisent la fonction d'intensité par une somme de Gaussiennes, c'est le Gaussian Mixture Cardinalized Probability Hypothesis Density (GM-CPHD) [117, 108] ou le GMPHD pour la version non cardinalisée [114, 64, 12]. Différentes hypothèses sont alors utilisées. On considère que la cible suit un modèle gaussien, $f(x|\gamma) = N(x; F\gamma, Q)$, et la vraisemblance d'une mesure par rapport à une cible est gaussienne $f(z|x) = N(z; Hx, R)$. On considère aussi que les probabilités de détection et de survie sont constantes (même si on verra plus loin que ces deux probabilités peuvent être variables). L'intensité a posteriori d'un RFS peut s'écrire sous la forme d'un mélange de gaussiennes $v_k = \sum_i w_{k,i} N(x; m_{k,i}, P_{k,i})$, et l'intensité des cibles naissantes est aussi un RFS modélisé par un mélange de gaussiennes $\gamma_k = \sum_i w_{k,i}^\gamma N(x; m, P_{k,i}^\gamma)$. Nous avons choisis de détailler l'implémentation du GM-CPHD dans la section 3.11.

3.11 Gaussian Mixture Cardinalized Probability Hypothesis Density (GMCPHD)

3.11.1 Notations

Notation	Signification
$A_{k k-1}$	Variable A a priori de l'instant k
$A_{k k}$	Variable A a posteriori de l'instant k
$v_{k k-1}$	Fonction d'intensité a priori des cibles
$w_{k k-1,i}$	Poids a priori de la gaussienne i
$m_{k k-1,i}$	Moyenne a priori de la gaussienne i
$P_{k k-1,i}$	Matrice de covariance a priori de la gaussienne i
γ_k	Intensité des cibles naissantes
J_k	Nombre de gaussiennes modélisant $v_{k k}$
J_{max}	Nombre maximum de gaussiennes modélisant $v_{k k}$
$P_\Gamma(n)$	Probabilité d'avoir n cibles naissantes
C_j^l	Nombre de combinaisons de j éléments parmi l
P_s	Probabilité de survie
$\langle a, b \rangle$	Produit scalaire des variables a et b
$a!$	Factorielle de a
$p_c(n)$	Probabilité d'avoir n fausses alarmes
$e_j(Z)$	Fonction élémentaire symétrique d'ordre j de l'ensemble Z
$q_k^j(z)$	Vraisemblance de z par rapport a la gaussienne j
$c_k(z)$	Densité de fausses alarmes
N_k	Nombre estimé de cibles
N_{max}	Nombre maximum de cibles
P_d	Probabilité de détection du capteur

TABLE 3.7 – Notations utilisées pour le GMCPHD

3.11.2 Introduction

Le filtre d'estimation est basé sur le CPHD (voir description à la section 3.9). Nous utilisons l'implémentation de ce filtre qui modélise les différents ensembles finis de variables aléatoires (RFS) par des sommes de gaussiennes. Les hypothèses suivantes sont donc effectuées :

- l'intensité a posteriori du RFS représentant l'ensemble des cibles s'écrit sous la forme d'un mélange de gaussiennes :

$$v_k = \sum_i w_{k,i} N(x; m_{k,i}, P_{k,i})$$

$m_{k,i}$ est la moyenne de la gaussienne i , et $P_{k,i}$ est sa covariance,

- l'intensité des cibles naissantes est aussi un RFS et s'écrit sous la forme d'un mélange de gaussiennes :

$$\gamma_k = \sum_i w_{k,i}^\gamma N(x; m_i, P_{k,i}^\gamma)$$

m est la moyenne de la gaussienne i , et $P_{k,i}^\gamma$ est sa covariance.

Nous verrons dans la suite les détails des différentes étapes permettant le suivi des pistes.

3.11.3 Prédiction

Les équations de prédiction du filtre CPHD sont donc utilisées avec les hypothèses décrites précédemment.

L'état de l'ensemble des pistes résultant de l'instant précédent $v_{k|k-1}(x)$ est prédit grâce aux équations de prédiction du filtre. La distribution de probabilité du nombre de cibles $p(n)$ est aussi prédite en utilisant la probabilité de survie des cibles P_s et la distribution de probabilité du nombre de nouvelles cibles $P_{\Gamma,k}(n)$. Cette étape de prédiction est complètement décorrélée du capteur utilisé.

Les équations de prédiction du GMCPHD sont :

$$\begin{cases} v_{k|k-1}(x) = \sum_{i=1}^{J_{k-1}} w_{k|k-1,i} N(x; m_{k|k-1,i}, P_{k|k-1,i}) + \gamma_k(x) \\ p_{k|k-1}(n) = \sum_{j=0}^n P_{\Gamma,k}(n-j) \sum_{l=j}^{\infty} C_j^l (1-P_s)^{l-j} P_s^j p_{k-1|k-1}(l) \end{cases}$$

J_{k-1} étant le nombre de gaussiennes représentant les pistes de l'instant précédent, et N_γ le nombre de gaussiennes représentant les nouvelles cibles détectées. Il y a après l'étape de prédiction $J_{k-1} + N_\gamma$ gaussiennes représentant l'intensité du RFS a priori. L'état des gaussiennes représentant les nouvelles cibles est développé dans le paragraphe 3.11.4. L'état des gaussiennes prédites, c'est à dire leur moyenne et leur covariance, provient des équations de prédiction du filtre de Kalman :

$$m_{k|k-1} = F_k m_{k-1|k-1}$$

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + Q_{k-1}$$

$$w_{k|k-1,i} = P_s \times w_{k-1|k-1,i}$$

La distribution à priori de la probabilité d'avoir n cibles est calculée par la somme des probabilités que parmi n cibles, il y a $n - j$ cibles qui soient de nouvelles cibles, et j cibles qui soient des cibles survivantes de l'instant précédent.

3.11.4 Naissance des cibles

Pour la naissance des cibles, deux techniques différentes peuvent être utilisées. Si la naissance des cibles est localisée en des endroits particuliers (lors de l'observation d'un couloir, l'apparition des cibles est uniquement située aux deux bouts du couloir), alors le RFS de naissance $\gamma_k(x)$ est une somme de gaussiennes localisées aux endroits précis (la moyenne est centrée sur ces endroits et la covariance englobe ces espaces) ayant des poids $w_{k,i}^\gamma$ assez faibles [116, 113].

Si la naissance des cibles n'est pas localisée en un endroit précis de la scène, le RFS de naissances est modélisé par une gaussienne pour chaque mesure non associée à une gaussienne existante mais proche statistiquement d'anciennes mesures qui n'étaient pas non plus associées avec des gaussiennes. Le RFS de naissance est alors construit à partir de gaussiennes centrées sur la scène observée, possédant une grande matrice de covariance, et un poids faible [107].

En pratique, un fenêtrage statistique (voir section 3.4.3) est effectué entre l'ensemble des pistes prédites et l'ensemble des mesures capteur. Lorsqu'une mesure est hors du fenêtrage de l'ensemble des pistes prédites, une nouvelle gaussienne est créée, dans l'hypothèse où cette mesure correspond à une nouvelle cible. Différentes méthodes de modélisation pour la naissance des cibles existent, un exemple peut être trouvé dans [86].

3.11.5 Mise à jour

La probabilité a posteriori qu'il y ait n cibles $p_{k|k}(n)$ est calculée à partir de la vraisemblance $\Psi_k^0[w_{k|k-1}, Z_k](n)$ qu'il y ait n cibles sachant Z_k l'ensemble des mesures reçues, la probabilité a priori qu'il y ait n cibles $p_{k|k-1}(n)$, et d'un terme de normalisation $\langle \Psi_k^0[w_{k|k-1}, Z_k], p_{k|k-1} \rangle$. $\langle A, B \rangle$ est le produit scalaire du vecteur A et B .

$$p_{k|k}(n) = \frac{\Psi_k^0[w_{k|k-1}, Z_k](n) \cdot p_{k|k-1}(n)}{\langle \Psi_k^0[w_{k|k-1}, Z_k], p_{k|k-1} \rangle} \quad (3.35)$$

(3.36)

$$\begin{aligned} & \Psi_k^u[w_{k|k-1}, Z_k](n) \\ &= \sum_{j=0}^{\min(|Z_k|, n)} (|Z_k| - j)! P_c(|Z_k| - j) \left[\frac{n!}{(n - (j+u))!} \frac{(1 - P_d)^{n - (j+u)}}{\langle 1, w_{k|k-1} \rangle^{j+u}} \right] e_j(\Xi(v_{k|k-1}, Z)) \end{aligned}$$

$P_c(|Z| - j)$ est la probabilité d'avoir $(|Z| - j)$ fausses alarmes, $|Z|$ le cardinal de l'ensemble des mesures, les fausses alarmes du capteur sont modélisées par un processus de Poisson. La probabilité de détection du capteur P_d est notée ici comme un paramètre constant. Nous verrons dans la suite à la section 4.7 comment utiliser une fonction de probabilité. $e_j(\Xi(v, Z))$ correspond à la notation de la fonction symétrique élémentaire, elle est définie par :

$$e_j(Z) = \sum_{S \subseteq Z, |S|=j} \prod_{z \in S} z \quad (3.37)$$

Elle est basée sur les éléments de l'ensemble $\Xi(v_{k|k-1}, Z)$. Cet ensemble est constitué des vraisemblances entre pistes et mesures $q_k^{(j)}(z)$ pondérées par la probabilité de détection P_d et le poids des pistes $w_{k|k-1}^{(j)}$.

$$\Xi(v_{k|k-1}, Z) = \{P_d w_{k|k-1}^T q_k(z), z \in Z\} \quad (3.38)$$

$$w_{k|k-1} = [w_{k|k-1}^{(1)}, \dots, w_{k|k-1}^{(J_{k|k-1})}]^T \quad (3.39)$$

$$q_k(z) = [q_k^{(1)}(z), \dots, q_k^{(J_{k|k-1})}(z)]^T \quad (3.40)$$

$$q_k^j(z) = N(z, H m_{k|k-1,j}, R + H P_{k|k-1,j} H^T) \quad (3.41)$$

Concernant la mise à jour de l'état des pistes, chaque piste prédite est mise à jour avec chaque nouvelle mesure. Chaque piste prédite est aussi mise à jour en cas de non détection. On obtient donc $(|Z| + 1)J_{k|k-1}$ nouvelles gaussiennes. Le poids des pistes $w_{k|k}^j$ mis à jour par une mesure z est calculé par :

$$w_{k|k}^j = \frac{P_d w_{k|k-1}^{(j)} q_k^{(j)}(z)}{c_k(z)} \frac{\langle \Psi_k^1[w_{k|k-1}, Z_k \setminus \{z\}], p_{k|k-1} \rangle}{\langle \Psi_k^0[w_{k|k-1}, Z_k], p_{k|k-1} \rangle} \quad (3.42)$$

$\Psi_k^1 [w_{k|k-1}, Z_k \setminus \{z\}]$ décrit la vraisemblance qu'il y ait n cibles sachant l'ensemble des cibles et l'ensemble des mesures diminué de la mesure utilisée pour la mise à jour.

$\langle \Psi_k^0 [w_{k|k-1}, Z_k], p_{k|k-1} \rangle$ est un terme de normalisation. $c_k(z)$ est la densité de fausse alarme. Les poids associés aux gaussiennes mises à jour en cas de non détection sont calculés par :

$$w_{k|k}^{(j)} = (1 - P_d) \frac{\langle \Psi_k^1 [w_{k|k-1}, Z_k], p_{k|k-1} \rangle}{\langle \Psi_k^0 [w_{k|k-1}, Z_k], p_{k|k-1} \rangle} w_{k|k-1}^{(j)} \quad (3.43)$$

L'état a posteriori des cibles mises à jour par une mesure est calculé en reprenant les équations de mise à jour du filtre de Kalman :

$$K_k^{(j)} = P_{k|k-1}^{(j)} H^T [H P_{k|k-1}^{(j)} H^T + R]^{-1} \quad (3.44)$$

$$m_k^{(j)}(z) = m_{k|k-1}^{(j)} + K_k^{(j)}(z - H m_{k|k-1}^{(j)}) \quad (3.45)$$

$$P_k^{(j)} = [Id - K_k^{(j)} H] P_{k|k-1}^{(j)} \quad (3.46)$$

3.11.6 Probabilité de détection variable

L'hypothèse de probabilité constante de détection et de survie n'est pas obligatoire, en effet seulement quelques modifications des équations des filtres précédents permettent d'utiliser des probabilités qui dépendent de la moyenne des gaussiennes par exemple [77]. Dans les équations du filtre nous avons ainsi remplacé les P_d par $P_d(m_{k-1|k-1})$ et les termes $(1 - P_d)$ par $\sum_j (1 - P_d(m_{k-1|k-1,j})) \frac{w_{k|k-1}^{(j)}}{\sum_l w_{k|k-1}^{(l)}}$ sauf le terme pré-multiplicateur de la mise à jour du poids de la gaussienne avec une non détection (3.43). De même la probabilité de survie P_s peut être variable et remplacée par $P_s(m_{k-1|k-1,j})$ dans la prédiction du RFS, mais par $P_s = \sum_j P_s(m_{k-1|k-1,j}) \frac{w_{k|k-1}^{(j)}}{\sum_l w_{k|k-1}^{(l)}}$ dans la prédiction de la probabilité de n cibles. Ci-dessous sont présentées les différentes équations impactées par une probabilité de détection, ainsi qu'une probabilité de survie variable :

$$\left\{ \begin{array}{l} v_{k|k-1}(x) = \sum_{i=1}^{J_{k-1}} P_s(m_{k-1|k-1,i}) w_{k-1|k-1,i} N(x, F m_{k-1|k-1,i}, F P_{k-1|k-1,i} F^T + Q) + \gamma_k(x) \\ P_{ss} = \sum_j P_s(m_{k-1|k-1,j}) \frac{w_{k|k-1}^{(j)}}{\sum_l w_{k|k-1}^{(l)}} \\ p_{k|k-1}(n) = \sum_{j=0}^n P_{\Gamma,k}(n-j) \sum_{l=j}^{\infty} C_j^l (1 - P_{ss})^{l-j} P_{ss}^j p_{k-1|k-1}(l) \end{array} \right. \quad (3.47)$$

$$\begin{aligned} & \Psi_k^u[w_{k|k-1}, Z](n) \\ &= \sum_{j=0}^{\min(|Z|, n)} (|Z| - j)! p_c(|Z| - j) \left[\frac{n!}{(n - (j+u))!} \frac{\left(\sum_j (1 - P_d(m_{k-1|k-1,j})) \frac{w_{k|k-1}^{(j)}}{\sum_l w_{k|k-1}^{(l)}} \right)^{n - (j+u)}}{\langle 1, w_{k|k-1} \rangle^{j+u}} \right] e_j(\Xi(v_{k|k-1}, Z)) \\ & w_{k|k-1} = [P_d(m_{k|k-1}^{(1)}) w_{k|k-1}^{(1)}, \dots, P_d(m_{k|k-1}^{(J_{k|k-1})}) w_{k|k-1}^{(J_{k|k-1})}]^T \end{aligned} \quad (3.48)$$

$$w_{k|k}^j = \frac{P_d(m_{k|k-1}^{(j)}) w_{k|k-1}^{(j)} q_k^{(j)}(z)}{c_k(z)} \frac{\langle \Psi_k^1[w_{k|k-1}, Z_k \setminus \{z\}], p_{k|k-1} \rangle}{\langle \Psi_k^0[w_{k|k-1}, Z_k], p_{k|k-1} \rangle} \quad (3.49)$$

$$w_{k|k}^{(j)} = (1 - P_d(m_{k|k-1}^{(j)})) \frac{\langle \Psi_k^1[w_{k|k-1}, Z_k], p_{k|k-1} \rangle}{\langle \Psi_k^0[w_{k|k-1}, Z_k], p_{k|k-1} \rangle} w_{k|k-1}^{(j)} \quad (3.50)$$

Ainsi, pour le GMCPHD, chaque gaussienne représentant la position des cibles est associée à une probabilité de détection qui correspond à la valeur de la probabilité de détection du capteur au point de la moyenne de la gaussienne représentant la cible. Cette moyenne correspond à l'espérance de la position de la cible, or cette position est imprécise, ce qui est modélisé par la matrice de covariance de cette gaussienne. Nous souhaitons donc prendre en compte l'imprécision de l'estimation de la position de la cible pour choisir la probabilité de détection du capteur associée à cette cible. La probabilité de détection choisie correspond donc à une moyenne de la probabilité de détection pondérée par la probabilité du positionnement de la cible. $P_d(m_{k|k-1}^{(j)})$ devient $P_d^{(j)}$, c'est à dire la probabilité de la cible j :

$$P_d^{(j)} = \int \int P_d(x, y) f_j(x, y) dx dy \quad (3.51)$$

où $f_j(x, y)$ est la fonction de densité de la gaussienne j .

Après l'étape de mise à jour, le filtre GMCPHD utilise des méthodes de simplification pour réduire le nombre de gaussiennes, et ainsi permettre une utilisation temps réel du filtre.

Ces méthodes sont présentées dans le paragraphe suivant.

3.11.7 Réduction du nombre de gaussiennes

La réduction du nombre de gaussiennes permet de réduire considérablement le temps de calcul du filtre. En effet, à chaque instant le nombre de gaussiennes augmente exponentiellement.

$$J_{k+1} = (|Z_k| + 1) \times J_k \quad (3.52)$$

J_k étant le nombre de gaussiennes à l'instant k et $|Z_k|$ le nombre de mesures à l'instant k .

Pour réduire ce nombre de gaussiennes, une étape de Pruning et une étape de Merging sont effectuées [114].

L'étape de Pruning consiste à éliminer toutes les gaussiennes dont le poids est inférieur à un seuil d'élimination $U_{pruning}$.

L'étape de Merging consiste, quant à elle, à rassembler plusieurs gaussiennes qui sont proches statistiquement en une seule gaussienne. La notion de distance statistique correspond à la distance de Mahalanobis utilisée aussi dans le fenêtrage statistique. La covariance utilisée dans cette distance est celle de la gaussienne ayant le poids le plus important. On définit tout d'abord un nombre J_{max} de gaussiennes, c'est à dire un nombre de gaussiennes suffisant pour décrire les cibles et permettant un temps de calcul limité. Si le nombre de gaussiennes à la sortie de l'étape de Pruning est supérieur à J_{max} , alors on effectue une étape de Merging sur la gaussienne ayant le poids maximum parmi les gaussiennes, c'est à dire que l'on mélange toutes les gaussiennes proches statistiquement de celle là.

La gaussienne résultante est décrite par les paramètres suivants :

$$\begin{aligned} j &= \operatorname{argmax}_{i \in I_k} w_{k|k}^{(i)} \\ L &= \left\{ i \in I \mid (m_{k|k}^{(i)} - m_{k|k}^{(j)})^T (P_{k|k}^{(j)})^{-1} (m_{k|k}^{(i)} - m_{k|k}^{(j)}) < U_{merging} \right\} \\ \tilde{w}_{k|k}^{(l)} &= \sum_{i \in L} w_{k|k}^{(i)} \\ \tilde{m}_{k|k}^{(l)} &= \frac{1}{\tilde{w}_{k|k}^{(l)}} \sum_{i \in L} w_{k|k}^{(i)} m_{k|k}^{(i)} \\ \tilde{P}_{k|k}^{(l)} &= \frac{1}{\tilde{w}_{k|k}^{(l)}} \sum_{i \in L} w_{k|k}^{(i)} (P_{k|k}^{(i)} + (\tilde{m}_{k|k}^{(l)} - m_{k|k}^{(i)})(\tilde{m}_{k|k}^{(l)} - m_{k|k}^{(i)})^T) \end{aligned} \quad (3.53)$$

Tant que le nombre de gaussiennes est supérieur à J_{max} , on effectue un Merging sur la gaussienne de poids maximum parmi les gaussiennes restantes (c'est à dire les gaussiennes

qui n'ont pas été déjà utilisées dans un mélange de gaussiennes ou qui en sont le résultat). Généralement le nombre J_{max} est défini à partir du nombre maximum de cibles à détecter, par exemple $J_{max} = 2 \times N_{max}$.

Ces deux étapes de réduction du nombre de gaussiennes sont appliquées après la mise à jour des gaussiennes.

D'autres méthodes plus sophistiquées de simplification sont disponibles dans [91].

3.11.8 Évaluation du nombre de cibles

L'évaluation du nombre de cibles à l'instant k peut se faire à partir de la probabilité de n cibles :

$$N_k = \sum_{n=0}^{\infty} n p_{k|k}(n) \quad (3.54)$$

De même, le nombre de cibles peut aussi être défini grâce aux poids des gaussiennes :

$$N_k = \sum_j w_{k|k-1}^{(j)} \quad (3.55)$$

Ces définitions ne garantissent pas un nombre entier, nous pouvons définir le nombre de cibles de la façon suivante :

$$N_k = \underset{n \in \{1, \dots, \infty\}}{\operatorname{argmax}} p_k(n) \quad (3.56)$$

3.11.9 Fonction élémentaire symétrique

La fonction symétrique élémentaire est utilisée dans les équations de mise à jour du filtre GMCPHD.

Cette fonction d'ordre j d'une séquence finie d'éléments A , utilisée dans les équations du filtre CPHD, se définit par :

$$e_j(A) = \sum_{S \subseteq A, |S|=j} \prod_{a \in S} a \quad (3.57)$$

3.11.9.1 Exemple

A titre d'exemple regardons les valeurs de la fonction symétrique élémentaire pour une séquence de 4 éléments $A = (x_1, x_2, x_3, x_4)$ pour les différents ordres possibles :

$$\begin{cases} e_0(A) = 1 \\ e_1(A) = x_1 + x_2 + x_3 + x_4 \\ e_2(A) = x_1x_2 + x_1x_3 + x_1x_4 + x_2x_3 + x_2x_4 + x_3x_4 \\ e_3(A) = x_1x_2x_3 + x_1x_2x_4 + x_1x_3x_4 + x_2x_3x_4 \\ e_4(A) = x_1x_2x_3x_4 \end{cases} \quad (3.58)$$

La fonction $i \mapsto e_i(A)$ est maximale lorsque i correspond au nombre d'éléments de A qui ont une valeur supérieure à 1.

3.11.9.2 Forme récursive

La fonction symétrique élémentaire est coûteuse en temps de calcul, mais elle peut être calculée de façon récursive. La complexité du calcul devient alors $\mathcal{O}(N)^2$, avec N la taille de la séquence d'éléments. Voyons les équations nécessaires pour le calcul récursif de la fonction symétrique élémentaire d'un ensemble $X = \{x_1, \dots, x_N\}$.

Pour l'initialisation, on a :

$$\begin{cases} \forall j \in \{1, \dots, N\}, \sigma_{1,j} = x_1 + \dots + x_j \\ \forall i \in \{2, \dots, N\}, \sigma_{i,1} = 0 \end{cases} \quad (3.59)$$

Ensuite récursivement, on calcul les éléments $\sigma_{i,j}$:

$$\forall (i, j) \in \{2, \dots, N\}, \sigma_{i,j} = \sigma_{i,j-1} + x_j \sigma_{i-1,j-1} \quad (3.60)$$

On obtient donc les coefficients $e_j(X)$:

$$\forall i \in \{1, \dots, N\}, e_i = \sigma_{i,N} \quad (3.61)$$

Ainsi, en reprenant l'exemple précédant pour une séquence de 4 éléments (x_1, x_2, x_3, x_4) , on peut, par exemple, calculer la valeur de e_2 grâce aux $\sigma_{i,j}$:

$$\begin{aligned}
 e_2 = \sigma_{2,4} &= \overbrace{\sigma_{2,2} + x_3 \sigma_{1,2}}^{\sigma_{2,2} + x_3 \sigma_{1,2}} + x_4 \overbrace{\sigma_{1,3}}^{x_1 + x_2 + x_3} \\
 &= \overbrace{\sigma_{2,2}}^{\sigma_{2,1} + x_2 \sigma_{1,1}} + x_3 \overbrace{\sigma_{1,2}}^{x_1 + x_2} + x_4 \cdot (x_1 + x_2 + x_3) \\
 &= \overbrace{\sigma_{2,1}}^0 + x_2 \overbrace{\sigma_{1,1}}^{x_1} + x_3 \cdot (x_1 + x_2) + x_4 \cdot (x_1 + x_2 + x_3) \\
 &= 0 + x_2 x_1 + x_3 \cdot (x_1 + x_2) + x_4 \cdot (x_1 + x_2 + x_3) \\
 &= x_1 x_2 + x_1 x_3 + x_1 x_4 + x_2 x_3 + x_2 x_4 + x_3 x_4
 \end{aligned} \tag{3.62}$$

Nous venons de voir dans cette section les éléments essentiels pour l'usage et l'implémentation d'un filtre GMCPHD. Le chapitre 4 est consacrée à l'usage de ce filtre dans notre cadre applicatif.

3.12 Comparaison de filtres

La méthode du plus proche voisin est la méthode la plus simple à mettre en œuvre, par contre elle est vite limitée dans des scénarios complexes de pistage. Elle est rudimentaire et gère très mal les cas de fausses alarmes ou les cas de cibles proches. De plus la naissance et la mort des cibles ne sont pas gérées explicitement et donc nécessitent un rajout pour rendre le système complet.

Le PDA et le JPDA permettent quant à eux la gestion des non détections et des fausses alarmes en plus de la gestion du bruit affectant les mesures. Cependant ils ne sont pas capables d'initialiser de nouvelles pistes, le nombre de pistes à gérer est constant. Un avantage du PDA est sa simplicité de mise en œuvre pour régler le problème de plusieurs mesures provenant d'une même cible. Le JPDA est relativement simple aussi. La plus grosse limitation de ces deux méthodes est la connaissance a priori du nombre de cibles. Les pistes doivent être initialisées grâce à un filtre supplémentaire au pistage, même s'il existe un filtre dérivé de ces filtres : l'IPDA qui propose une initialisation des pistes [68]. De plus avec le JPDA, le nombre de matrices d'association croît exponentiellement avec le nombre de cibles dans un même cluster.

Le MHT et le CPHD permettent tous deux de gérer correctement le problème d'association des pistes, de fausses alarmes, de non détections, de naissance et mort des pistes. Les deux filtres semblent pouvoir permettre des évolutions en temps réel (considérant nos applications envisagées). Dans la suite, nous nous orienterons vers ces deux filtres. La prochaine étape sera pour nous la comparaison de ces filtres dans notre contexte applicatif dans le chapitre 4.

Chapitre 4

Pistage de cibles en contexte autoroutier

Sommaire

4.1	Notations	92
4.2	Introduction	93
4.3	Architecture de fusion proposée	94
4.4	Choix du filtre de pistage	96
4.5	L'apport de la classification au filtre	103
4.6	Paramétrage du filtre	107
4.7	Problématique d'occultation	118
4.8	Problématique de corrélation de données	129

4.1 Notations

Notation	Signification
$A_{k k-1}$	Variable A a priori de l'instant k
$A_{k k}$	Variable A a posteriori de l'instant k
$v_{k k-1}$	Fonction d'intensité a priori des cibles
$w_{k k-1,i}$	Poids a priori de la gaussienne i
$m_{k k-1,i}$	Moyenne a priori de la gaussienne i
$P_{k k-1,i}$	Matrice de covariance a priori de la gaussienne i
γ_k	Intensité des cibles naissantes
J_k	Nombre de gaussiennes modélisant $v_{k k}$
J_{max}	Nombre maximum de gaussiennes modélisant $v_{k k}$
$P_\Gamma(n)$	La probabilité d'avoir n cibles naissantes
C_j^l	Le nombre de combinaisons de j éléments parmi l
P_s	La probabilité de survie
$\langle a, b \rangle$	Le produit scalaire des variables a et b
$a!$	Factoriel de a
$p_c(n)$	La probabilité d'avoir n fausses alarmes
$e_j(Z)$	La fonction élémentaire symétrique d'ordre j de l'ensemble Z
$q_k^j(z)$	Vraisemblance de z par rapport a la gaussienne j
$c_k(z)$	Densité de fausses alarmes
N_k	Nombre estimé de cibles
N_{max}	Nombre maximum de cibles
P_d	Probabilité de détection du capteur
$P_d^{(j)}$	Probabilité de détection associée à la gaussienne j
$P_d(m_{k k-1}^{(j)})$	Probabilité de détection pour l'état de la moyenne de la gaussienne j
X_{type}	Variable aléatoire décrivant le type de cible
$C_{i,j}$	Élément de la matrice de confusion
$P_{d_{occ}}$	Probabilité de détection prenant en compte les occultations
$P_{\overline{occ}}$	Probabilité qu'il n'y ait pas d'occultation
P_{oj}	Probabilité qu'il y ait une partie de la cible j occultante
σ_U	Écart type de la gaussienne représentant la largeur de la cible occultante
σ_G	Écart type de la gaussienne marginale de la position de la cible occultante sur l'axe Γ
Γ	Droite passant par la moyenne de la gaussienne occultante et perpendiculaire à Γ^\perp
Γ^\perp	Droite reliant la zone à détecter au capteur

TABLE 4.1 – Notations utilisées pour le GMCPHD

4.2 Introduction

Les chapitres précédents nous ont permis d'introduire le cadre applicatif de notre travail, la variété des systèmes de fusion existants ainsi que l'ensemble des outils permettant cette fusion. Nous allons dans ce chapitre nous concentrer sur notre travail, sur les choix qui ont été faits et sur l'explication de ces choix. Ce chapitre concentre donc l'ensemble de nos contributions. Nous présentons ainsi l'architecture du système de fusion de radar et caméra (en tant que capteurs intelligents, c'est à dire qu'ils fournissent des données pré-traitées) construit dans le cadre des applications d'aide à la conduite. Nous verrons tout d'abord l'architecture modulaire et asynchrone de fusion utilisée. Cette architecture est basée sur un filtre de pistage, le choix du filtre de pistage entre les filtres MHT et CPHD présentés dans le chapitre 3 sera également justifié. Les apports et modifications du filtre de pistage classique effectués afin de l'ajuster à notre domaine applicatif et à nos deux capteurs sont présentés. En effet, nous avons modifié la définition de l'espace d'état des cibles pour pouvoir gérer le pistage de multi-types de cibles. La définition de l'ensemble des paramètres utilisés par le filtre de pistage est aussi étudiée. Des méthodes sont proposées et décrites afin de gérer certains problèmes de pistage inhérents aux capteurs utilisés tels que les occultations et la corrélation des données.

4.3 Architecture de fusion proposée

4.3.1 Fusion modulaire

Les capteurs que l'on cherche à fusionner sont des capteurs intelligents et industriels. La sortie de ces capteurs est une liste de détections avec pour chaque cible détectée une estimation de la position et de la vitesse de ces cibles. Ces capteurs sont considérés comme des boîtes noires, c'est à dire que le traitement interne au capteur est inconnu. Les données brutes de chaque capteur sont inaccessibles. On considère alors chaque capteur comme un module ayant une sortie similaire, une liste de détections avec des estimations sur l'état de ces détections. Nous cherchons à tirer parti de cette modularité en proposant un système de fusion flexible et modulaire. Ainsi de nouveaux capteurs intelligents peuvent être facilement intégrés ou retirés. Nous choisissons donc un système de fusion centralisée haut niveau.

4.3.2 Pistage Multi-cibles Multi-capteurs (MSMTT)

Nous allons utiliser un filtre d'estimation, de pistage, pour fusionner les informations des capteurs. Nous avons vu dans le chapitre précédent que plusieurs filtres de l'état de l'art peuvent satisfaire l'ensemble de nos exigences tout en gérant les différents défauts de nos capteurs (bruit de mesure, non détections, et fausses alarmes) : le MHT et le CPHD. Nous avons effectué une étude préliminaire avec les données réelles de nos capteurs pour évaluer ces filtres afin de choisir le plus adapté à notre application. Le filtre CPHD semble être le filtre d'estimation qui correspond le mieux à nos données capteurs. Ce choix présenté dans la section 4.4 est basé sur l'étude comparative des filtre MHT et CPHD.

4.3.3 Capteurs asynchrones

Dans la littérature, la plupart des systèmes multi capteurs utilisant un filtre RFS choisissent de synchroniser dans le temps les données des différents capteurs. La problématique du MSMTT (Multi Sensor Multi Target Tracking) est un domaine de recherche qui reste à approfondir [58, 59]. Cependant, une solution applicative de MSMTT basée sur les RFS a été développée, cette méthode est appelée *approche de correction itérative* pour la généralisation de plusieurs capteurs [9, 37, 29]. Elle consiste à appliquer la phase corrective du filtre (PHD ou CPHD) pour chaque ensemble de mesures envoyées par les différents capteurs. Ces approches MSMTT partent du principe que les capteurs sont synchronisés et renvoient au même moment leur observation. La plupart du temps, ce n'est pas le cas, il faut alors

synchroniser les mesures. La synchronisation des capteurs nécessitent de sous-échantillonner ou de sur-échantillonner les données capteurs (voir Figure 2.1). Pour éviter cette perte d'information, tout en restant temps réel, nous choisissons une méthode de fusion ne nécessitant pas de synchronisation. A chaque réponse de capteur, les observations sont envoyées au filtre d'estimation. Certains problèmes de synchronisme, dus au temps de traitement des données différents entre capteurs, peuvent alors se produire. Le travail de Cedric Tessier [103] donne une solution applicative à ce type de problème.

TABLE 4.2 – Ecart type de l’erreur de position entre le résultat du filtre et la référence de position du capteur Lidar.

	Camera	Radar
écart type de l’erreur en position pour le TOMHT (en m)	1.6	1.45
écart type de l’erreur en position pour le GMCPHD (en m)	1.58	1.41

4.4 Choix du filtre de pistage

Afin de choisir le filtre le plus adapté à notre application et à nos capteurs, nous avons décidé de mener une étude comparative des filtres MHT et CHPD. Ces deux filtres permettent théoriquement de gérer le bruit de mesure, les fausses alarmes, les non détections, la mort et la naissance des cibles naturellement. Nous avons donc conduit une étude préliminaire portant sur 30 minutes de conduite sur autoroute (à environ 130 km/h) et en ville (à environ 50 km/h). Nous avons fait la comparaison sur deux critères, l’estimation du nombre de cibles, et la précision de l’état des cibles estimé par les filtres TOMHT (paragraphe 3.7.3) et GMCPHD (section 3.11). Nous avons utilisé les données radar ou caméra pour évaluer ces filtres avec des données réelles (séparément, nous ne voulons pas évaluer la fusion des deux capteurs), nous avons aussi utilisé une webcam afin d’obtenir une visualisation de la situation routière (l’image de la caméra n’est pas accessible). Nous avons tout d’abord testé la précision de nos filtres en comparant l’estimation de la position des pistes avec la position estimée par un lidar. le lidar n’est pas utilisé par les filtres mais juste une valeur “vraie” de la position des cibles. Nous pouvons voir, d’après les résultats du tableau 4.2, que la précision des deux filtres est équivalente.

La comparaison de ces filtres a été faite grâce à une comparaison de programmes codés en langage Matlab. Sans nous donner une information exacte sur la possibilité temps réel des ces programmes, nous pouvons tout de même dire que le programme du filtre TOMHT est environ 10 fois plus rapide que le programme du GMCPHD. En Matlab, le temps moyen du temps de calcul du TOMHT est de 0.0046 secondes par instant d’acquisition, alors que le temps du GMCPHD est de 0.0418.

L’estimation du nombre de cibles du filtre permet de se rendre compte de la gestion de la naissance et mort des cibles, ainsi que de la gestion des non détections et des fausses alarmes. Nous avons, dans la suite, comparé les résultats des filtres concernant ce critère. Nous montrons, à partir de deux situations particulières, les différences typiques concernant le nombre estimé de cibles, nous ayant aidé à choisir parmi les deux filtres.

4.4.1 Situation sur autoroute




FIGURE 4.1 – Image webcam de la situation : 4 voitures sont détectées

Nous avons testé nos filtres dans des situations autoroutières. Il est difficile d’analyser les différences de comportement de chacun des filtres concernant l’estimation du nombre de cibles de manière globale. Nous avons donc choisi d’analyser certaines situations où des différences claires apparaissaient. Nous décrivons une des situations dans ce paragraphe. Nous analysons la situation représentée dans la Figure 4.1.

Pour cette situation, le radar détecte 4 voitures roulant devant notre véhicule. Le mouvement des voitures est représenté sur la figure 4.2a. Les positions de notre véhicule, les mesures radar et les résultats des filtres sont représentées sur les Figures 4.2b, 4.2c. Pour les voitures 2, 3, 4, les résultats des différents filtres sont similaires. Mais concernant la voiture 1, des différences de comportement sont visibles.

En réalité, nous pouvons même distinguer trois zones de comportement différentes. Pour chaque zone, un des deux ou les deux filtres ont une mauvaise estimation de la situation, et donc du nombre de cibles. Ces situations sont plus facilement visibles sur la Figure 4.3. Pour la première zone d’erreurs (nommée A), la voiture 1 change de ligne et est occultée pendant 15 instants d’acquisition par le véhicule 2. Le filtre TOMHT est le premier à perdre la cible et le dernier à la détecter lors de la réapparition (visible sur la Figure 4.4 représentant l’estimation du nombre de cible par les filtres). Concernant la zone B, le radar ne détecte pas le véhicule 1 pendant un instant d’acquisition, puis l’estimation de la position de cette voiture change beaucoup l’instant d’après.

La différence de comportement des filtres de la zone C provient de la différence importante

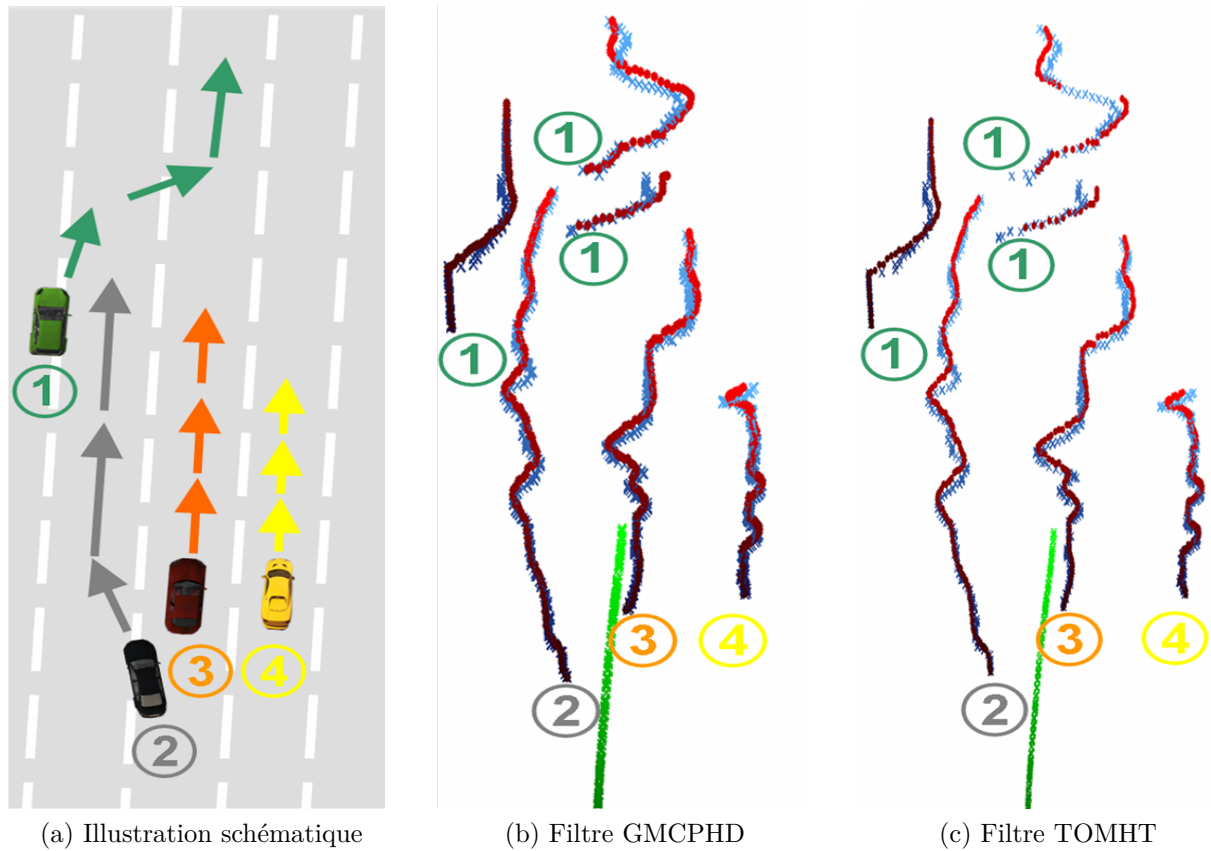


FIGURE 4.2 – Bird-view représentant 4 voitures détectées. Les mesures du capteur sont représentées en bleu, la trajectoire de notre véhicule est en vert, et le résultat du filtre est en rouge.

entre les mesures et les positions prédites. Le filtre GMCPHD n'a aucun mal à suivre le véhicule 1, alors que le TOMHT réagit différemment. Puisque les mesures radar sont distantes entre deux instants d'acquisition, le filtre TOMHT considère ces mesures comme provenant de deux cibles différentes. La position prédite de la cible est trop loin de la mesure radar, le fenêtrage statistique du TOMHT empêche l'association de la mesure avec la piste et la piste est alors perdue. Le GMCPHD est moins dépendant de la distance entre piste prédite et mesure puisque la mise à jour de chaque piste se fait avec toutes les mesures, quelque soit la distance entre la piste et la mesure et aussi grâce à l'utilisation de la distribution du nombre de cibles.

Nous pouvons bien voir les différents résultats concernant l'estimation du nombre de cibles représentée sur la Figure 4.4. Le GMCPHD permet d'obtenir de meilleurs résultats concernant ce critère.

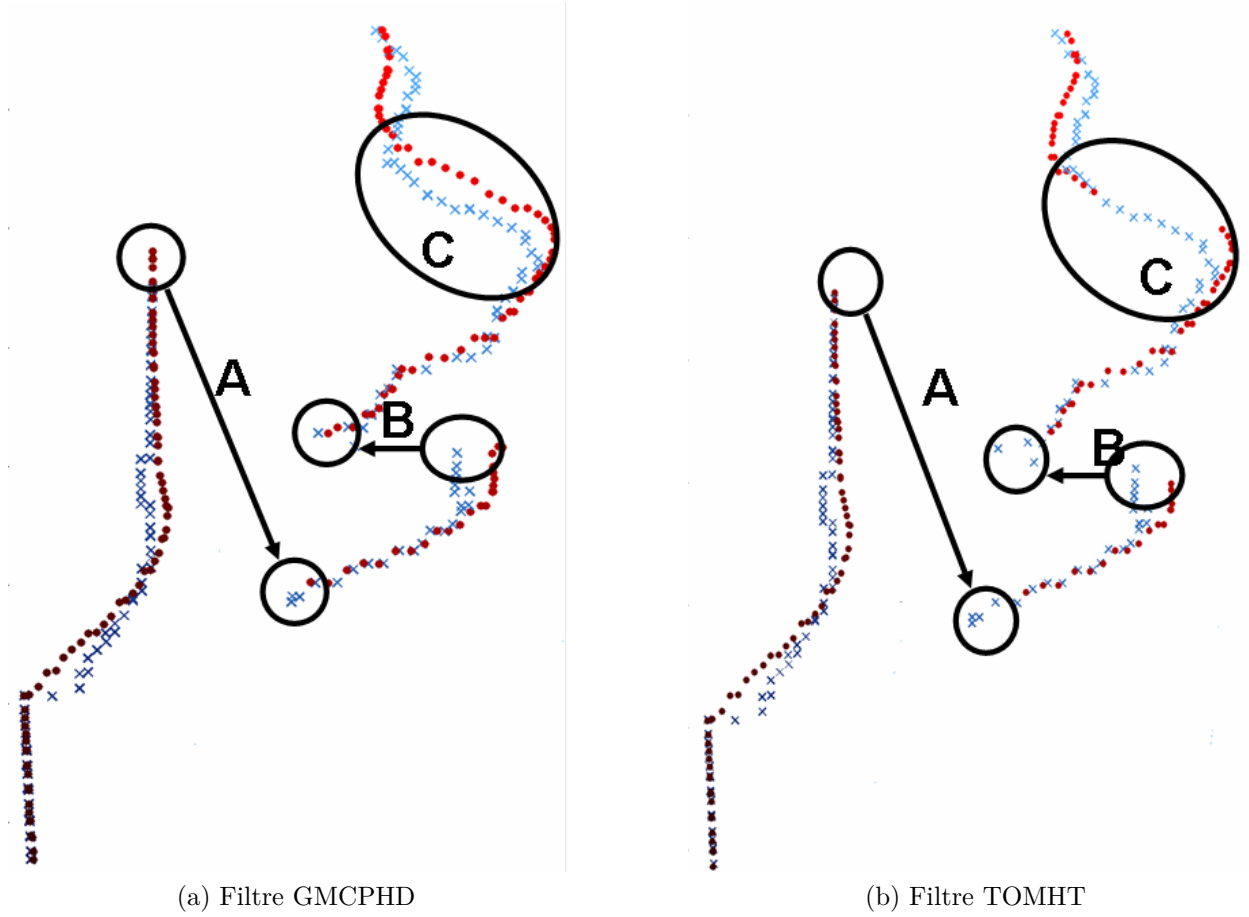


FIGURE 4.3 – Ces figures représentent un zoom sur une situation problématique de la Figure 4.2. Les différences entre les filtres sont mises en évidence par des cercles noirs.




FIGURE 4.4 – Le nombre de mesures de la situation de la Figure 4.2 est représenté en rouge. Le nombre estimé de cibles par le TOMHT (bleu) et par le GMCPHD (vert) est aussi représenté.

	TOMHT	GMCPHD
Temps de calcul	+	-
Précision	=	=
Naissance/mort des pistes	-	+
Association	-	+
Vision	local	global

TABLE 4.3 – Tableau comparatif des filtres TOMHT et GMCPHD

4.4.2 Situation sur route





FIGURE 4.5 – Image webcam d’une situation basse vitesse : le passage à un rond point


Dans les situations routières, les ronds-points sont de plus en plus fréquents, nous montrons dans ce paragraphe un exemple de situation de rond-point avec des mesures caméra (voir Figure 4.5). Par exemple, lorsque que la voiture blanche fait le tour du rond point, le bruit affectant la position de la caméra augmente (voir Figure 4.6). Comme pour l’exemple du paragraphe précédent, lorsque le bruit affectant l’état de la mesure du capteur est plus important que prévu, le filtre TOMHT a du mal à suivre la cible. La distance entre la piste prédite et la mesure est trop importante, et le filtre TOMHT considère qu’il y a deux cibles différentes à suivre devant notre véhicule (voir Figure 4.7).

4.4.3 Choix


Pour conclure, Une synthèse des critères observés est montré dans le tableau 4.3. Nous pouvons dire que la précision des filtres en terme de position est équivalente. Le temps de calcul est nettement moins important avec le TOMHT, mais nous pouvons quand même espérer être temps réel avec le GMCPHD. L’estimation du nombre de cibles est déterminante, dans les applications ADAS, une non détection ou une fausse alarme a un impact direct sur l’appréciation de la fonction par le conducteur. La naissance et la mort des cibles est



(a) Illustration schématique, le rectangle noir représente notre véhicule, et la voiture verte représente le camion de la figure 4.5 que nos capteurs observent.



(b) Filtre GMCPHD



(c) Filtre TOMHT

FIGURE 4.6 – Bird-view représentant le passage d’une voiture à un rond point. La trajectoire estimée par les mesures des Figures (b) et (c) devrait correspondre à la trajectoire du schéma (a) sans le bruit affectant les mesures. Les mesures du capteur sont représentées en bleu, et les résultats des filtres sont en rouge. Les différences entre les comportements des deux filtres sont mises en évidence par des cercles noirs.

globalement meilleure avec le GMCPHD, c’est à dire que la naissance en cas de détection est plus rapide, et la mort en cas de non détection est plus lente.

Ce type de comportement est dépendant des paramètres des filtres choisis. Nous avons cependant essayé d’appliquer des paramètres équivalents aux deux filtres sans aucun a priori de fonctionnement des filtres. Cependant, un critère lié à l’estimation du nombre de cibles n’est pas dépendant des paramètres. L’association mesure/piste est meilleure avec le filtre GMCPHD, surtout lors d’exemples d’augmentation rapide et inattendue du bruit de mesure. Ce comportement étant du à l’absence de fenêtrage statistique du GMCPHD.




FIGURE 4.7 – Le nombre de mesures est représenté en rouge. Le nombre estimé de cibles par le TOMHT (bleu) et par le GMCPHD (vert) est aussi représenté.

Ces différents résultats de comparaison nous amènent donc à préférer l'utilisation du filtre GMCPHD pour nos applications, la justesse de l'estimation du nombre de cibles étant déterminante dans notre cas.

4.5 L'apport de la classification au filtre

Dans cette section, le filtre de pistage GMCPHD est modifié afin de pouvoir distinguer différents types de cibles sur la route. L'ensemble des entités routières est supposé composé de piétons, de voitures, de camions, de vélos et de motos, et il est important, du point de vue applicatif de distinguer si c'est un piéton ou une voiture qui est devant notre véhicule. Les capteurs utilisés nous fournissent une classification des cibles détectées, il est alors intéressant d'utiliser ces informations pour en déduire le type des différentes pistes du filtre de MTT. Ces informations pourront aussi améliorer les performances d'association du filtre GMCPHD, une piste de type *piéton* ayant moins de probabilité d'être associée à une mesure classée *voiture*. La méthode la plus évidente est de considérer chaque ensemble de cibles de type différent comme un RFS à part entière et d'utiliser un filtre GMCPHD différent pour chaque RFS.

Cependant il est important de noter que le résultat de classification des capteurs n'est pas forcément juste, cette information peut être erronée. Un exemple d'erreur de classification est montré dans la section 5.4. Un changement de classification d'une cible serait mal géré avec un filtre de pistage pour chaque type de cible. Dans le cas d'une cible classifiée comme un piéton qui devient, après quelques instants d'acquisition, une voiture (ce qu'elle est réellement), alors, la piste du RFS piéton va disparaître, le filtre pensant que le piéton n'existe plus. Une nouvelle piste voiture va apparaître dans le RFS voiture. Le problème étant qu'il y aura une perte d'information, l'état estimé de la cible lorsqu'elle était piéton ne sera pas pris en compte pour l'estimation de l'état de la nouvelle piste voiture. De plus, le nombre estimé de cibles pourra être faussé, ce nombre correspondant à la somme de piétons et de voitures par exemple. En effet, il faut un certain intervalle de temps pour que la piste piéton disparaisse après la disparition de la mesure piéton, alors que la nouvelle piste voiture pourra être déjà créée, il y aura donc deux pistes pour représenter la même cible.

Dans la littérature, une autre méthode est envisagée. Dans [80] les auteurs choisissent d'utiliser des informations capteur supplémentaires pour mieux décrire les cibles, et de les utiliser pour lever certaines ambiguïtés d'association mesure/piste, par le calcul de vraisemblance mesure/piste utilisant ces informations. Nous choisissons d'utiliser le même principe avec notre filtre. De fait, l'espace d'état de chaque piste est étendu, cela signifie que l'état de chaque piste comprend une description de la classification de chaque piste. Une fonction de masse de probabilité (en anglais *probability mass function*, *pmf*) d'une variable discrète aléatoire X_{type} décrivant le type de cible est associée à chaque gaussienne.

Pour nos capteurs, une cible peut être un objet inconnu, un piéton, un vélo, une voiture, ou un camion :

$$X_{type} \in \{t_i\}_{0 \leq i \leq 4} \quad (4.1)$$

avec $t_0 = \text{inconnu}$, $t_1 = \text{pieton}$, $t_2 = \text{velo}$, $t_3 = \text{voiture}$, $t_4 = \text{camion}$.

Nous verrons tout d'abord comment cette *pmf* est calculée à chaque instant. Puis, nous verrons ensuite comment elle peut être utilisée pour améliorer les performances d'association du filtre.

A l'arrivée d'une mesure, comme pour l'état des cibles (voir la section 3.11.5), le type de cible est corrigé par cette mesure. La correction s'effectue par une mise à jour Bayésienne de la probabilité du type de cible :

$$P_k(x_{type} = t_i) = \frac{P(z_{type}|x_{type} = t_i)P_{k-1}(x_{type} = t_i)}{\sum_{j=0}^4 P(z_{type}|x_{type} = t_j)P_{k-1}(x_{type} = t_j)}$$

$P_k(x_{type} = t_i)$ est la probabilité à l'instant k que la cible soit de type t_i . $P(z_{type}|x_{type} = t_i)$ est la vraisemblance de la mesure par rapport à la cible concernant le type. Cette valeur provient de la matrice de confusion caractérisant le système de classification du capteur. La méthode utilisée pour l'estimation des valeurs de cette matrice de confusion est détaillée dans la section 4.6.

$$C_{i,j} = (P(z_{type} = t_j|x_{type} = t_i)) \quad (4.2)$$

Nous l'avons déjà évoqué : cette nouvelle probabilité associée à chaque piste peut être utilisée pour améliorer les performances d'association du filtre. Cela concerne l'association mesure/piste mais aussi l'association piste/piste. Les étapes du filtre impactées par ce changement sont décrites dans la suite.

En prenant en compte le type de cible estimé et le résultat de classification de l'observation du capteur, nous pouvons préciser la vraisemblance de la mesure à la cible. Par exemple, si le capteur détecte ce qu'il pense être un piéton, et que l'on sait que la classification des piétons est plutôt bonne, cette mesure sera plus vraisemblablement reliée à une cible estimée comme étant un piéton.

Ainsi, la vraisemblance d'une mesure par rapport à une cible est modifiée dans le filtre, telle que :

$$q_k^{(j)}(z) = f(z|x) = N\left(z; Hm_{k|k-1,j}, R + HP_{k|k-1,j}H^T\right) \times f_{type}(z_{type}|x_{type})$$

$N\left(z; Hm_{k|k-1,j}, R + HP_{k|k-1,j}H^T\right)$ est la vraisemblance cinématique utilisée habituelle-

ment dans les MTT. $f_{type}(z_{type}|x_{type})$ est la vraisemblance de type entre la mesure et la cible, elle est définie par :

$$f_{type}(z_{type}|x_{type}) = \sum_{j=0}^4 P(z_{type}|x_{type} = t_j) P_{k-1}(x_{type} = t_j)$$

De même, lors de l'étape de simplification du MTT, lorsque deux cibles sont suffisamment proches, leurs gaussiennes sont mélangées afin de réduire leur nombre. Pour cela, une distance est calculée entre deux gaussiennes. Comme pour la vraisemblance, cette distance est modifiée pour prendre en compte le type de cible estimé : pour cela on utilise la distance de Bhattacharyya [39] entre deux densités de probabilités discrètes. La distance entre une cible 1 et une cible 2 est donc définie par :

$$D(x^1, x^2) = D_{etat}(x_{etat}^1, x_{etat}^2) + D_{type}(x_{type}^1, x_{type}^2)$$

$$D_{type}(x_{type}^1, x_{type}^2) = -\ln \left(\sum_{j=0}^4 \sqrt{P_k(x_{type}^1 = t_j) P_k(x_{type}^2 = t_j)} \right)$$

$D_{etat}(z_{etat}|x_{etat})$ est la distance utilisée habituellement dans les MTT, z_{etat} , x_{etat} étant modélisés par des gaussiennes dans le MTT, la distance utilisée est la distance de Mahalanobis. Lors de l'étape de naissance, les distances entre les mesures et les cibles sont calculées afin de repérer les cibles naissantes. Cette distance, entre cible et mesure, est aussi améliorée afin de prendre en compte le type de cible. On lui rajoute une distance concernant le type, définie par :

$$D(z_{type}, x_{type}) = -\ln \left(\sum_{j=0}^4 P(z_{type}|x_{type} = t_j) P_{k-1}(x_{type} = t_j) \right)$$

Pour aller plus loin dans l'utilisation des informations de type de cibles, nous aurions pu utiliser la probabilité de type de pistes pour contraindre le mouvement cinématique des cibles. Comme nous verrons dans le paragraphe 4.6.1, il existe différents modèles cinématiques, cette possibilité trouve son intérêt dans la variété des applications de pistage de la littérature. Il pourrait être intéressant de différencier le modèle cinématique d'un piéton de celui d'une voiture, comme cela a été fait dans [63]. Cette possibilité d'amélioration de notre filtre est expliquée plus en détails dans les perspectives à la section 6.2.

Pour conclure cette section, les équations du GMCPHD sont modifiées au niveau du calcul des vraisemblances et des distances pour pouvoir prendre en compte l'information de type

de cibles. Ces modifications impactent l'association mesure/piste, mais aussi la probabilité d'existence de chaque piste et l'estimation du nombre de pistes, à travers l'utilisation de la vraisemblance mesure/piste. Dans la section suivante, notre travail a surtout concerné l'estimation des paramètres du filtre GMCPHD pour une utilisation optimale de ce dernier.

4.6 Paramétrage du filtre

Pour une utilisation optimale du filtre GMCPHD, quelques paramètres doivent être définis. Nous appelons paramètres, l'ensemble des valeurs, fonctions, constantes ou non, qui doivent être choisies ou estimées préalablement à l'application par le créateur de l'application. Nous pouvons différencier trois catégories de paramètres :

- les paramètres applicatifs, c'est à dire dont le choix dépend de l'application visée. Par exemple, le modèle cinématique des cibles est un paramètre applicatif, ou encore la probabilité de survie des cibles. Ce type de valeur est lié uniquement aux types de cibles envisagés, et donc à l'application,
- les paramètres liés au capteurs, c'est à dire dont le choix dépend du capteur utilisé. Par exemple, les paramètres modélisant les imperfections des capteurs, tels que le bruit de mesure, les performances de détection...,
- les paramètres d'implémentation, c'est à dire dont le choix dépend d'une expertise ou de décision purement arbitraire liée au coût calculatoire du système.

Les méthodes de choix de paramètres sont souvent liées à une expertise du système, nous souhaitons décrire dans cette section l'expertise permettant la définition de ces paramètres afin de rendre facilement accessible la reprise de ce travail.

4.6.1 Paramètres applicatifs

Le choix des composantes du vecteur d'état ainsi que le choix du repère font partie des paramètres applicatifs. Un choix couramment fait est de se placer dans un repère absolu, ce choix est particulièrement justifié dans les applications de multi-vehicules [8], ou dans les applications nécessitant la localisation simultanée de notre véhicule et des véhicules environnants. Nous choisissons pour notre application de nous placer dans notre repère véhicule, ce repère étant plus simple (ne nécessitant pas de localisation de notre véhicule) et suffisant pour notre application. En sachant que, pour certains résultats de la section 5.5.2 nous avons utilisé un repère absolu pour simplifier la vision et la compréhension de ceux-ci. Le vecteur d'état est, quant à lui, composé de la position et de la vitesse relative de la cible sur un axe latéral et longitudinal (axes X et Y de la Figure 4.8) :

$$x_k = \begin{pmatrix} x & v_x & y & v_y \end{pmatrix}^T$$

Nous devons aussi choisir la modélisation cinématique des cibles. Dans la littérature, certains modèles sont classiquement utilisés [61] :




FIGURE 4.8 – Les capteurs caméra radar et lidar sont positionnés pour détecter au mieux les entités routières. La position et la vitesse relative sont estimées par les capteurs. Le repère utilisé est défini par les axes X et Y.

- vitesse constante,
- accélération constante,
- manœuvre,
- piétons.

Nous choisissons d'utiliser le modèle de vitesse constante, c'est à dire que la matrice de transition de l'équation 3.10 est définie par :

$$F = \begin{pmatrix} 1 & T_e & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T_e \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

La matrice de bruit de modèle est quant à elle définie par :

$$Q = \begin{pmatrix} \sigma_{lat}^2 \times \frac{T_e^3}{3} & \sigma_{lat}^2 \times \frac{T_e^2}{2} & 0 & 0 \\ \sigma_{lat}^2 \times \frac{T_e^2}{2} & \sigma_{lat}^2 \times T_e & 0 & 0 \\ 0 & 0 & \sigma_{longi}^2 \times \frac{T_e^3}{3} & \sigma_{longi}^2 \times \frac{T_e^2}{2} \\ 0 & 0 & \sigma_{longi}^2 \times \frac{T_e^2}{2} & \sigma_{longi}^2 \times T_e \end{pmatrix}$$

Avec σ_{lat}^2 fixé à 0.1 et $\sigma_{longi}^2 = 1$, T_e étant le laps de temps entre le temps d'acquisition de

la mesure précédente et le temps d'acquisition actuel.

4.6.2 Paramètres d'implémentation

Le GMCPHD a l'avantage de n'utiliser que très peu de paramètres d'implémentation, c'est à dire des paramètres essentiellement choisis grâce à l'expertise du constructeur du système. Nous pouvons noter tout de même le nombre de cibles maximum, celui-ci servant essentiellement à limiter le coût calculatoire du filtre. Si ce nombre est trop grand, alors le filtre GMCPHD sera difficilement temps réel, par contre si il est trop petit, par exemple si il y a 13 cibles à détecter et que ce paramètre est mis à 10, alors 3 cibles ne seront pas détectées, le filtre estimant qu'il y a uniquement 10 cibles. Nous choisissons de fixer à 12 ce paramètre, nous faisons alors l'hypothèse que nous n'allons pas avoir à observer plus de 12 cibles simultanément. C'est une hypothèse forte, qui sera confirmée dans le chapitre des résultats 5.

De même lors du fenêtrage statistique de l'étape de naissance 3.11.4, un seuil est utilisé pour définir si une mesure est trop loin de la piste prédite. Nous choisissons de fixer ce seuil à 15, la valeur de ce seuil joue uniquement sur la vitesse de naissance des cibles, cette valeur est définie empiriquement.

Il faut savoir que l'importance de ce seuil est minimisée car il ne sert pas à exclure une mesure de l'ensemble des mesures, mais juste à créer une nouvelle gaussienne pour accélérer le processus de création de piste. En sachant que, même sans la création d'une gaussienne spécifique lors de l'étape de naissance, une nouvelle piste peut être créée, car lors de l'étape de mise à jour, l'ensemble des mesures (sans fenêtrage statistique) est utilisé pour corriger chaque piste.

4.6.3 Paramètres de capteur

Les paramètres liés aux performances du capteur sont ceux qui permettent de personnaliser le filtre de pistage au capteur renvoyant à un moment donné l'information. Ce sont ces paramètres qui permettent un fonctionnement cohérent du filtre avec différents capteurs. Nous rappelons que nous cherchons à utiliser les données renvoyées par un radar et une caméra, ces données étant composées des estimations de position et vitesse, ainsi que de la classification pour chaque cible détectée.

Pour le filtre de pistage GMCPHD, nous avons besoin de connaître certaines performances des capteurs :

- la probabilité de détection,
- la densité de fausses alarmes,
- le bruit de mesure, celui de la position estimée, celui de la vitesse,
- les erreurs de classification.

Nous avons évoqué dans la section 1.2 que nos capteurs sont des “capteurs intelligents”. Les détails de traitement des données ne sont pas disponibles. Nous devons donc estimer les performances de chaque capteur sans a priori sur le traitement effectué. Nous décidons d’évaluer la performance de chaque capteur en le comparant à une vérité terrain. Une vérité terrain est une connaissance vraie de ce que renvoient les capteurs. La première solution, pour obtenir une vérité, est de se placer dans un environnement contrôlé où chaque entité à détecter possède un système précis de localisation, tel que une centrale inertielle ou un DGPS. Nous pensons alors que les performances évaluées ne correspondront pas à la réalité. En effet, l’environnement peut avoir un impact important sur les performances. Nous choisissons d’évaluer les performances des capteurs en situation réelle. La construction de la vérité terrain doit donc se baser uniquement sur des capteurs embarqués dans le véhicule sans aucune connaissance a priori. Notre vérité terrain sera construite à partir d’un Lidar, d’un Radar, et d’une Caméra. Le Lidar est utilisé pour estimer la position des cibles, le radar est lui utilisé pour estimer la vitesse relative, et la Caméra est utilisée pour classifier les cibles. Le Lidar n’est pas utilisé directement dans notre système de fusion mais uniquement dans la création de la vérité terrain pour les raisons évoquées dans la section 1.2.

4.6.4 Vérité terrain


D’un extrême à l’autre, les méthodes utilisées pour construire une vérité terrain peuvent être entièrement faites par l’humain ou entièrement autonomes. Pour la méthode manuelle : chaque instant d’acquisition est manuellement vérifié et annoté, l’avantage étant la vérité des informations, l’inconvénient par contre étant le temps nécessaire au traitement. Pour la deuxième méthode : une méthode de traitement et d’analyse automatique est utilisée, l’avantage étant la rapidité de traitement, l’inconvénient étant que la justesse de la vérité terrain créée n’est pas assurée.

Étant donnée la quantité des données à analyser afin de réaliser des statistiques correctes sur les performances de capteur, nous avons choisi une méthode semi-supervisée, c’est à dire qu’une première phase de traitement des données est effectuée automatiquement, et une deuxième phase de vérification est faite manuellement par un superviseur.


Un objet de vérité terrain est défini comme une association d’une détection Lidar, d’une



(a) Image de Webcam



(b) Représentation d'une vue du dessus des détections lidar (avec des rectangles pleins) et détections camera (rectangles vides). Les objets associés (lidar/caméra) sont représentés avec une couleur identique. Les non détections et les fausses alarmes de la caméra sont représentées en vert. Dans cet exemple, nous pouvons voir trois cibles détectées par le lidar et la caméra (il y a donc 3 associations : rouge, bleu, et marron) et un objet uniquement détecté par le lidar. Ces associations correspondent a des objets de vérité terrain partielle.



(c) Représentation d'une vue du dessus des détections lidar+caméra (avec des rectangles pleins) et détections radar (avec des cercles vides). Les objets associés (lidar+caméra/radar) sont représentés avec une couleur identique. Les non détections et les fausses alarmes du radar sont représentées en vert. Dans cet exemple, nous pouvons voir deux associations entre un objet de vérité partielle et une détection radar (en rouge, et marron), deux objets non détectés par le radar et un objet uniquement détecté par le radar.

FIGURE 4.9 – L'image d'une webcam est utilisée pour aider l'humain superviseur à comprendre la situation. Deux vues de dessus sont utilisées pour représenter la vérité terrain, une pour représenter les associations de détectons lidar/caméra, une autre pour représenter les associations entre les objets de vérité partielle et les détections radar.

détection Radar, et d'une détection Caméra avec la position estimée par le Lidar, la vitesse du Radar et la classification de la Caméra.

Pour la première étape, les associations entre les détections des différents capteurs sont effectuées automatiquement. Nous faisons l'hypothèse que le Lidar détecte l'ensemble des cibles, autrement dit, il n'existe pas de non détection Lidar. L'association entre les trois capteurs est faite grâce aux associations Lidar/Caméra et Lidar/Radar. Cette application n'a pas besoin d'être temps réel, les acquisitions n'ont pas besoin d'être traitées en ligne, elles peuvent être enregistrées puis traitées ensuite sur table pour construire la vérité terrain. A tous les instants d'acquisition, la distance globale de chaque combinaison possible d'association est calculée.

Exemple. Soit l_1, l_2, l_3 l'ensemble des détections Lidar et c_1, c_2 l'ensemble des détections Caméra, nous notons $a_{i,j}$ l'association de l_i et c_j . L'ensemble des combinaisons d'associations possibles est donc :

$$A = \{(a_{1,1}, a_{2,2}), (a_{2,1}, a_{1,2}), (a_{3,1}, a_{2,2}), (a_{1,1}, a_{3,2}), (a_{3,1}, a_{1,2}), (a_{2,1}, a_{3,2})\}$$

Pour chaque combinaison, nous calculons la distance globale, c'est à dire la somme des distances, avec une distance de Mahalanobis. L'ensemble des objets de vérité terrain correspond à la combinaison d'association avec la distance globale la plus petite.

Dans l'étape suivante, des vérifications sont faites par un superviseur humain pour corriger la vérité terrain préliminaire. Une image provenant d'une webcam supplémentaire est utilisée pour faciliter la compréhension de la scène par le superviseur, la caméra utilisée étant un capteur industriel, l'image acquise par cette caméra n'est pas accessible. Tout d'abord, en cas d'association anormale entre une détection caméra (respectivement Radar) et une détection Lidar, une correction est faite manuellement. Ensuite la détection de l'ensemble des cibles est contrôlée.

Cette méthode permet de créer une vérité terrain fiable concernant la détection de l'ensemble des cibles, et concernant l'état de chaque cible. Lorsque le Lidar, le Radar, et la Caméra détectent la même cible, la vérité terrain créée est basée sur la position mesurée par le Lidar, la vitesse mesurée par le Radar, et la classification de la Caméra. Si au moins un des capteurs ne détecte pas la cible, l'objet de vérité terrain est créé sans l'attribut correspondant au capteur ne détectant pas la cible afin de valider l'existence de l'objet réel.

Finalement cette vérité terrain est utilisée pour collecter l'ensemble des erreurs de position de la Caméra (respectivement du Radar) et pour calculer la déviation standard de ces erreurs.

De même les performances en terme de probabilité de détection ou de nombre moyen de fausses alarmes sont évaluées à partir de la comparaison avec la vérité terrain. De plus les erreurs de classification sont évaluées.

L'estimation de ces paramètres est décrite dans la section 4.6.5 et l'impact de chacun de ces paramètres sur le fonctionnement du filtre de pistage est évalué dans la section 5.3.

4.6.5 Définition des paramètres

Nous comparons les données renvoyées par nos capteurs à la vérité terrain construite grâce à la méthode définie dans la section 4.6. Cette comparaison va nous permettre de définir la plupart des paramètres capteurs : le bruit affectant la position estimée des cibles, la probabilité de détection en fonction de l'état de la cible à détecter, la densité de fausses alarmes, et les erreurs de classification. L'estimation de ces paramètres est peu faite dans la littérature, provenant souvent d'une certaine expertise. Pourtant ces paramètres sont déterminants quant à la qualité du filtrage. D'ailleurs l'impact d'une mauvaise estimation de ces paramètres est ensuite évalué dans la section 5.3.

4.6.5.1 Identification du bruit de capteur

Dans ce paragraphe nous nous intéressons à l'identification du bruit de mesure utilisé pour modéliser la précision des positions mesurées par les capteurs (matrice de covariance R_k). L'erreur de bruit de capteur sur la position est modélisée par un bruit blanc gaussien. Nous récoltons l'ensemble des erreurs entre la position mesurée par le capteur et la position de l'objet réel afin d'en déduire l'écart type définissant la gaussienne modélisant l'erreur de position. Nous cherchons à vérifier la dépendance ou l'indépendance de cette erreur à l'état de la cible détectée (la dépendance par rapport à la position latérale ou longitudinale de la cible). Pour chaque type d'erreur (longitudinale ou latérale) et pour chaque capteur (radar ou caméra), nous créons une carte d'écart type d'erreur.

Le bruit affectant la position latérale et longitudinale de la cible par le radar semble indépendant de la position de la cible, nous le considérons donc constant (il est ainsi fixé à 3.97). Par contre, le bruit affectant la position mesurée par la caméra semble évoluer en fonction de l'état de la cible. La Figure 4.10 permet de représenter ce phénomène. Nous avons discrétisé la zone observée par nos capteurs par des cases de $2m \times 10m$, pour chaque case, nous avons collecté les erreurs de position affectant les cibles positionnées dans cette case. Nous en déduisons l'écart type représenté dans la Figure 4.10. Pour confirmer l'hypothèse de dépendance entre la position longitudinale de la cible et l'erreur de cette position par le capteur, nous avons




FIGURE 4.10 – Carte représentant l'écart-type de l'erreur caméra sur la position longitudinale des cibles. Chaque case représente la valeur de l'écart-type de l'erreur sur la position longitudinale pour l'ensemble des cibles positionnées dans la case.

modélisé l'ensemble des couples de valeurs (*position longitudinale*, *std erreur longitudinale*) par une fonction affine sur la Figure 4.11. Cette fonction est ensuite utilisée par le filtre pour estimer le bruit de capteur sur la position longitudinale en fonction de la position de la mesure ($std_{error} = 0.12 \times pos_{longi}$). Lors de l'analyse du bruit affectant l'erreur latérale des cibles, aucune dépendance n'est constatée, l'écart type du bruit est donc défini constant à 0.81.

4.6.5.2 Identification de la probabilité de détection

La probabilité de détection du Radar est analysée dans la Figure 4.12. La probabilité de détection est en fait la probabilité que le capteur détecte une cible à un instant donné sachant que la cible est présente. La probabilité de détection semble ne pas être dépendante directement des valeurs de position latérale et longitudinale des cibles. Une étude plus approfondie nous a permis de détecter la dépendance de la probabilité de détection avec l'angle de la cible (angle formé par la ligne entre la cible et le capteur et l'axe longitudinal). La Figure 4.13 présente les couples de valeur de détection de probabilité avec l'angle correspondant. A partir de cet ensemble de points, une fonction modélisant la relation entre l'angle et la probabilité de détection est créée (la courbe bleue de la Figure 4.13). Le filtre de pistage utilise cette fonction pour en déduire la probabilité de détection du capteur Radar en fonction de l'angle de la mesure.




FIGURE 4.11 – Les croix rouges proviennent de l'étude expérimentale et la ligne bleue modélise la relation entre l'erreur et la position longitudinale.




FIGURE 4.12 – Carte représentant le taux de détection du Radar. Chaque case représente la valeur de la probabilité de détection pour l'ensemble des cibles positionnées dans la case.




FIGURE 4.13 – Les croix rouges proviennent de l’étude expérimentale et la ligne bleue modélise la relation entre l’angle et la probabilité de détection du Radar.

Une analyse similaire est effectuée concernant la moyenne de fausses alarmes par instant d’acquisition pour la Caméra et le Radar et pour la probabilité de détection de la Caméra. Ces différents paramètres ne semblent pas dépendre de l’état des cibles. La moyenne de fausse alarmes par instant d’acquisition est donc fixée à 0.0116 et le même paramètre pour le Radar est fixé à 0.1302. La carte de la probabilité de détection semble montrer une valeur constante à l’intérieur d’un champ de vue fixe, ce champ de vue étant défini entre -25° et 25° . Il apparait après une étude plus approfondie des non détections de la caméra, que chaque non détection est liée à une occultation partielle ou totale. Cette étude nous a conduit à traiter le problème des occultations explicitement (voir section 4.7).

L’estimation de la matrice de confusion peut aussi être effectuée par une comparaison avec la vérité terrain. Cependant, statistiquement, nous n’avons pas observé assez de piétons, vélos, et camions pour en déduire une matrice de confusion pour chaque capteur. Nous avons pour l’instant basé l’estimation de cette matrice uniquement sur notre expertise.

$$(C_{ij})^{caméra} = (P(z_{type} = t_i | x_{type} = t_j))^{caméra} = \begin{pmatrix} 0.2 & 0.2 & 0.005 & 0 & 0 \\ 0.2 & 0.6 & 0.2 & 0 & 0 \\ 0.2 & 0.2 & 0.75 & 0 & 0 \\ 0.2 & 0 & 0 & 0.7 & 0.3 \\ 0.2 & 0 & 0 & 0.3 & 0.7 \end{pmatrix}$$

$$(C_{ij})^{radar} = (P(z_{type} = t_i | x_{type} = t_j))^{radar} = \begin{pmatrix} 0 & 0.33 \\ 0 & 0.33 \\ 0 & 0.33 \\ 0.5 & 0.0005 \\ 0.5 & 0.0005 \end{pmatrix}$$

Nous venons de voir l'estimation de chacun des paramètres capteurs. La méthode utilisée, bien que partiellement automatique, reste longue à mettre en place. Nous avons cherché dans la section 5.3 à évaluer l'impact des erreurs dans l'estimation de certains des paramètres.

Lors de l'analyse des performances de détection de la caméra, nous avons remarqué que la plupart des non détections caméra sont dues à des situations d'occultation. La section suivante décrit donc la solution que nous proposons pour résoudre les problèmes de non détection dus aux occultations des capteurs optiques.

4.7 Problématique d’occultation

Parmi les deux capteurs que nous cherchons à fusionner, il y a une caméra. Le défaut principal en matière de performance de détection est dû dans ce cas aux occultations partielles ou totales, c’est pourquoi cette section est consacrée à cette problématique.

4.7.1 Définition du problème

L’ensemble des capteurs optiques (Caméra ou Lidar) sont sensibles aux phénomènes d’occultation. Cela provient du fait que la lumière ne peut pas traverser un corps solide. Lorsque une occultation se produit, l’image de la caméra ne nous permet plus d’avoir les informations nécessaires à la compréhension de la scène. Au delà du problème général de l’ignorance, certains problèmes applicatifs découlent du problème de l’occultation. Dans le cas particulier des applications ADAS décrites dans la section 1.1, nous pouvons noter deux types de problèmes.

- Le premier cas concerne les applications de pré-crash piéton. Dans cette application, la détection des piétons est primordiale, et pourtant, dans la vie courante, il est habituel que les piétons se retrouvent dans des situations d’occultation avec d’autres entités routières (exemple montré sur la Figure 4.14). Les performances de détection seront augmentées s’il est possible de prévoir l’occultation. De même, la réactivité de l’application serait augmentée s’il est possible de prédire la réapparition du piéton lorsqu’il traverse une route après avoir été caché momentanément par une voiture.
- Le deuxième cas d’occultation problématique peut être décrit grâce à la Figure 4.15. Les applications de suivi de véhicule, tel que le DW ou l’ACC, sont alors concernées. Dans l’exemple de la Figure 4.15, une voiture verte suivie par une grise (portant la caméra et le système de suivi), la voiture noire se dirigeant dans l’autre sens va momentanément cacher la voiture suivie. Le problème inhérent est la disparition du véhicule vert suivi. Il ne faut pas alors que le système de régulation (ACC) pense que la voie est libre et donc se mette à accélérer pour ensuite décélérer lors de la réapparition de la voiture.


Cette section sera donc consacrée tout d’abord à une explication des solutions couramment mises en place dans la littérature pour palier ce genre de problème, puis nous décrirons la solution que nous proposons.

4.7.2 Gestion des occultations propre au système de détection

Comme énoncé dans le paragraphe précédent, le lidar et la caméra sont deux capteurs couramment utilisés dans les ADAS sensibles aux phénomènes d’occultation. Dans la littéra-



(a) Vue de Caméra




(b) Vue de haut

FIGURE 4.14 – Exemple d'une situation d'occultation



(a) Vue de Caméra



(b) Vue du haut

FIGURE 4.15 – Exemple d'une situation d'occultation

ture, la première solution pour gérer les occultations partielles est de les prendre en compte directement dans le système de détection. Une occultation partielle décrit par définition une situation où la cible occultée n'est que partiellement cachée, une partie de la cible est visible par le capteur, a contrario d'une occultation totale, où la cible occultée est complètement cachée du capteur.

Dans les cas d'occultation partielle, la détection de cible utilisant des critères de contour peut être robuste et détecter des cibles partiellement cachées [2, 30, 43]. Un apprentissage directement basé sur un apprentissage de cible partiellement occultée peut aussi être performant [72]. Cependant, dans les cas d'occultation totale, ces approches ne sont pas efficaces, la solution ne peut pas se trouver dans l'analyse des données brutes des capteurs mais dans la fusion d'information. Les approches résolvant directement ce problème dans le système de pistage sont maintenant considérées.

4.7.3 Gestion des occultations par le système de pistage

Avec les travaux précédents utilisant des données Lidar, la probabilité d'occultation est considérée binaire et est gérée directement par les cartes d'occupation avant d'être ensuite utilisée par un système de pistage. C'est la méthode utilisée par exemple par le filtre SMC-MTB (*sequential Monte Carlo multi-target Bayes*) dans [85]. Pour des applications de détection de différents types de cibles, des méthodes similaires sont utilisées [69][31]. La probabilité d'occultation est alors aussi utilisée pour améliorer la classification des objets détectés Lidar : si l'on sait qu'une voiture va être partiellement occultée, nous savons aussi que sa largeur sera réduite, or la classification avec des impacts lidar se base beaucoup sur la taille des objets, la connaissance de la taille réduite de la voiture pourra améliorer le résultat de la classification.

Ces méthodes de gestion des occultations fonctionnent très bien avec des données précises en position, telle que le sont les données Lidar. En effet, avec le Lidar, la position et la largeur des cibles sont bien estimées. De plus la zone d'occultation est bien connue, lorsque le Lidar a un impact sur un objet, il ne pourra rien détecter derrière cet objet, cette zone est alors obligatoirement occultée. Avec un capteur Caméra, c'est différent. Nous pouvons noter plusieurs imperfections impactant la certitude d'occultation :

1. Les positions de cibles sont bruitées.
2. Les détections caméra ne correspondent pas forcément à un objet physique, l'incertitude sur l'existence des pistes est à prendre en compte.
3. Le phénomène d'incertitude d'occultation est aussi à prendre en compte. Ce phénomène est montré sur l'exemple de la Figure 4.14. Bien qu'étant positionné derrière la voiture

verte, le piéton est uniquement caché partiellement (la hauteur de la voiture n'est pas complètement occultante). Étant donné que les systèmes de détection de caméra permettent maintenant la détection de cible partiellement cachée, il est difficile de prévoir si la caméra va détecter ce piéton. Nous parlons alors d'incertitude d'occultation

Dans le papier [3], les auteurs présentent une méthode de pistage de piéton à partir d'observations Caméra. Cette méthode permet de gérer le bruit affectant la position estimée des pistes en convoluant la zone a priori occultée avec un noyau 2D gaussien. Mais elle ne permet pas de prendre en compte le troisième problème énoncé précédemment des occultations avec une caméra. Nous présentons dans la suite une méthode qui permet de gérer l'ensemble des difficultés particulières aux données Caméra.

4.7.4 Probabilité de détection et occultations

La probabilité de détection P_d d'une zone donnée correspond à la capacité du capteur à repérer une cible existante dans la zone d'observation sachant qu'il y a une cible à cet endroit. La probabilité P_d est souvent dépendante de la position de la cible et de son état. Elle peut aussi être dépendante de l'état des autres cibles de la scène. Dans l'exemple de la Figure 4.14, un piéton est caché derrière une voiture. Le capteur, une caméra, ne détectera pas le piéton, la probabilité de détection P_d du piéton est diminuée par la présence de la voiture. C'est pour cette raison, que nous cherchons à gérer les occultations au travers de la probabilité de détection.

Pour chaque objet de la scène précédemment observé, nous cherchons à connaître la probabilité P_d qu'a le capteur de détecter cet objet à l'instant k . En effet, si grâce à l'historique du piéton, nous savons que celui-ci risque d'être occulté à l'instant k , la probabilité P_d doit être diminuée de façon à rendre compte de cette occultation. Ainsi, si cet objet n'est pas détecté à l'instant k , la probabilité d'existence de cet objet ne diminuera pas.

Nous cherchons donc à définir la probabilité de détection P_d du capteur pour chaque point de l'espace en fonction de l'état de l'ensemble des cibles, c'est à dire $P_d(x, y)$.

La probabilité de détection en un point (x, y) devient la probabilité de détection $P_d(x, y)$ du capteur seul multipliée par la probabilité P_{occ} qu'il n'y ait pas de cible entre le point (x, y) et le capteur :

$$P_{d_{occ}}(x, y) = P_d(x, y) \cdot P_{occ}(x, y) \quad (4.3)$$

S'il n'y a pas de cible entre le point (x, y) et le capteur, cela signifie qu'aucune cible

n'occulte le point (x, y) . En utilisant les probabilités totales, on peut donc exprimer P_{occ} par :

$$P_{occ}(x, y) = \prod_j (1 - w_j P_{o_j}(x, y)) \quad (4.4)$$

$P_{o_j}(x, y)$ est la probabilité qu'une partie de la cible j soit placée entre le point (x, y) et le capteur, c'est à dire la probabilité qu'une partie de la cible j occulte le point (x, y) . w_j est la probabilité a priori de l'existence réelle de la cible :

$$P_{o_j}(x, y) = \frac{\sigma_U \sqrt{2\pi}}{\sqrt{2 \cdot \pi(\sigma_G^2 + \sigma_U^2)}} e^{\frac{-(d^2)}{2\sqrt{\sigma_G^2 + \sigma_U^2}}}$$

où σ_U est l'écart type de la fonction P_U , et σ_G est l'écart type de la loi marginale de f sur l'axe Γ et d est la distance entre le point (x') et la moyenne de la gaussienne f_G^Γ (voir Figure 4.16).

Pour connaitre la probabilité $P_{o_j}(x, y)$, nous cherchons à calculer la probabilité $P_{part,j}(x', y')$ qu'une partie de la cible j soit positionnée en un point (x', y') situé entre le point (x, y) et le capteur. Pour pouvoir calculer ces probabilités de présence de partie de cible, il faut pouvoir prendre en compte la position des cibles, mais aussi leur largeur.

Dans la suite nous allons décrire la méthode choisie pour calculer cette probabilité tout d'abord en 1 dimension, nous verrons ensuite comment utiliser cette solution pour un problème de positionnement en 2 dimensions en passant par l'utilisation d'une marginale de la densité de probabilité de position.

4.7.4.1 Largeur des cibles

Pour simplifier, prenons l'exemple d'une voiture occultant une cible (un piéton). L'estimation de la position de la voiture représentée par une gaussienne va correspondre à la position G de son centre de gravité. Or un piéton peut être caché par une voiture même si celui-ci n'est pas juste derrière le centre de gravité de la voiture (voir Figure 4.14).

Pour bien comprendre, nous nous plaçons dans un espace à une dimension. La voiture est donc placée sur un axe (nous verrons plus tard comment passer à deux dimensions). Nous cherchons donc à calculer $P_X(x)$, c'est à dire la probabilité que la cible soit visible au point x , ce qui traduit la largeur de la voiture.

Pour exprimer la probabilité que la cible soit visible à un endroit, nous utilisons le résultat de la convolution entre une fonction représentant la largeur de la cible et une fonction représentant la probabilité de position de la cible.




FIGURE 4.16 – La marginale f_G^Γ suffit pour représenter la position de la cible dans le cadre du calcul de la probabilité des occultations car la position de la cible selon l'axe Γ^\perp ne modifie pas l'occultation résultante. $P_G^\Gamma(x') = f_G^\Gamma(x')dx'$ correspond bien à la somme des probabilités que la cible soit positionnée sur l'axe Γ^\perp .




FIGURE 4.17 – La position d’un point de la voiture (X) correspond à la somme de la position du centre de gravité de la voiture (G) et de l’abscisse du point de la voiture par rapport au centre de gravité de la voiture (U).

Démonstration Nous cherchons donc à obtenir une expression de la probabilité $P_X(x)$.

X est la variable aléatoire représentant la position d’un point de l’objet (pas forcément son centre de gravité) sur un axe Γ_x , et $P_X(x)$ correspondant à la probabilité qu’un point situé en x sur l’axe appartienne à la cible.

Comme nous le montre la figure 4.17 la variable aléatoire X peut être définie comme la somme des variables aléatoires G et U , $X = G + U$:

- G est la variable aléatoire représentant la position du centre de gravité de l’objet sur l’axe Γ_x , $P_G(x)$ correspond à la probabilité que le centre de gravité de la voiture soit placé au point x ,
- U est la variable aléatoire représentant l’abscisse d’un point de l’objet défini dans le repère ayant pour origine le centre de gravité de la voiture, $P_U(u)$ correspond donc à la probabilité qu’un point situé à une abscisse u du centre de gravité appartienne à la cible.

Considérant que $X = G + U$, nous cherchons à calculer la probabilité $P_X(x)$.

$$\begin{aligned}
 P_X(x) &= P_{G+U}(x) = P(G + U = x) = E[\mathbf{1}_x(G + U)] \\
 &= \int \int \mathbf{1}_x(g + u) dP_{G,U}(g, u) \\
 &= \int \int \mathbf{1}_x(g + u) dP_G(g) dP_U(u) \\
 &= \int \underbrace{\left(\int \mathbf{1}_{x-g}(u) dP_U(u) \right)}_{P_U(x-g)} dP_G(g) \\
 &= \int P_U(x - g) f_G(g) dg \\
 &= (P_U * f_G)(x)
 \end{aligned} \tag{4.5}$$

La fonction $\mathbf{1}_A(x)$ est définie par :

$$\mathbf{1}_A(x) = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases}$$

La probabilité qu'il y ait donc une partie de la cible au point x est définie par la convolution de P_U et f_G .

Exemples Voici quelques exemples permettant de comprendre la logique de cette convolution.

Supposons que la fonction f_G soit une impulsion de Dirac (voir Figure 4.18), c'est à dire que nous sommes sûrs de la position de la cible sur l'axe, et P_U est :

- soit une fonction rectangle non normée, la largeur de la fonction rectangle correspondant à la largeur de la cible. On considère que la cible à une largeur fixe et bien définie sur toute la hauteur de la cible. Donc l'occultation sera totale sur toute la largeur de la cible,
- soit une fonction gaussienne non normée (dont le maximum est 1), la variance de la gaussienne correspondant à la largeur de la cible. On considère alors que la largeur est moins bien définie, nous permettant alors de modéliser l'incertitude d'occultation.

On visualise facilement la fonction de mesure de probabilité P_X qui correspond à la convolution de ces deux fonctions. Dans ces deux cas, la convolution permet de centrer la fonction P_U sur l'impulsion de Dirac.

De même, si l'on considère que la fonction f_G est une somme de deux impulsion de Dirac




FIGURE 4.18 – Pour P_U étant une fonction rectangle non normée, ou une fonction gaussienne non normée (dont le maximum est 1), on visualise la fonction P_X qui correspond à la fonction P_U centré sur le dirac représentant la fonction f_G .




FIGURE 4.19 – Autour de chaque dirac, la zone correspondant à la largeur de la voiture a une probabilité d'occultation égale à 0.5, dûe au poids des diracs, lorsque ces zones se superposent la probabilité d'occultation est de 1.

pondérés par 0.5, la convolution de f_G et P_U nous permet d'obtenir une fonction de mesure de probabilité P_X cohérente.

Nous venons donc de voir que la convolution avec la fonction représentant la largeur permet d'introduire la largeur de la cible dans le calcul de la probabilité d'occultation.

4.7.4.2 Marginale de $f_G(x, y)$

Voyons maintenant comment nous pouvons utiliser cette convolution lorsque la position de la voiture est définie dans une zone à deux dimensions. Par exemple, si l'on prend le cas d'une cible dont l'état a priori est représenté par une gaussienne de fonction de densité

$f_G(x, y)$. Nous pouvons nous restreindre à l'utilisation de $f_G^\Gamma(x, y)$ (qui est la marginale de f suivant l'axe Γ) pour décrire la position de la cible, nous nous ramenons ainsi au cas présenté dans le paragraphe 4.7.4.1 utilisant une fonction f_G définie sur un axe. Γ^\perp est l'axe reliant un point de la scène (x, y) à notre capteur, Γ est l'axe perpendiculaire à Γ^\perp passant par la moyenne de $f_G(x, y)$.

On considère que la position de la cible suivant l'axe Γ^\perp est négligeable pour calculer le pouvoir occultant de la cible : pour le point x' de l'axe Γ , la marginale $f_G^\Gamma(x')$ représente bien la loi de densité de la cible de se positionner sur un des point y' de l'axe Γ^\perp (voir figure 4.16).

$$f_G^\Gamma(x') = \int_{(x', y') \in \Gamma'} f_G(x', y') dy' \quad (4.6)$$

$$P_G^\Gamma(x') = f_G^\Gamma(x') dx' = \underbrace{\int_{(x', y') \in \Gamma'} f_G(x', y') dy' dx'}_{\sum_{(x', y') \in \Gamma'} P_G(x', y')} \quad (4.7)$$

Connaissant maintenant l'expression de la fonction $f_G = f_G^\Gamma$ représentant la position de la cible sur l'axe Γ , Nous pouvons introduire la prise en compte de la largeur de la cible en convoluant f_G avec P_U . Nous définissons P_U comme une gaussienne non normée, ce choix nous permet une simplification de calculs pour la convolution en plus de considérer une largeur permettant de modéliser l'incertitude d'occultation. Nous obtenons ainsi :

$$P_{Oj}(x, y) = (f_G^\Gamma * P_U)(x') \quad (4.8)$$


$$(f_G^\Gamma * P_U)(x') = \frac{\sigma_U \sqrt{2\pi}}{\sqrt{2 \cdot \pi(\sigma_G^2 + \sigma_U^2)}} e^{\frac{-(d^2)}{2\sqrt{\sigma_G^2 + \sigma_U^2}}} \quad (4.9)$$

Où σ_U est l'écart type de la fonction P_U , et σ_G est l'écart type de la loi marginale de f sur l'axe Γ et d est la distance entre le point (x') et la moyenne de la gaussienne f_G^Γ .


Un exemple de calcul de probabilité d'occultation pour une cible est présenté sur la Figure 4.20.

Nous obtenons donc une nouvelle expression de la probabilité de détection prenant en compte l'état de l'ensemble des cibles à un moment donné.


Nous verrons dans la section suivante que cette probabilité peut encore être modifiée pour gérer la corrélation des données.



(a) Représentation de P_U de la cible 1



(b) Représentation de f_G de la cible 1, c'est à dire sa densité de probabilité de position



(c) Représentation de P_{O1} , c'est à dire la probabilité pour chaque point de la carte d'être occulté par le cible 1

FIGURE 4.20 – pour une cible décrite par les images (a) et (b). La fonction représentant la largeur de la cible est montré sur la Figure (a). La densité de probabilité de position de cette cible est montrée Figure (b), le rouge représente les valeurs importantes de la fonction f_G . La figure (b) et (c) sont des bird view de environnement frontal du véhicule. Pour la Figure (c), le rouge représente la plus haute probabilité d'occultation.

4.8 Problématique de corrélation de données

4.8.1 Définition du problème

Les capteurs utilisés sont des capteurs intelligents dont le traitement interne des données est inconnu. Cela signifie que les données en sortie du capteur ont probablement été déjà traitées. Les données brutes du capteur peuvent être déjà pistées dans le système interne de traitement du capteur. Ce type de pré-traitement est un problème, car il induit une dépendance entre les observations entre le temps k et le temps $k - 1$.

Or les systèmes de pistage sont basés sur l'hypothèse d'indépendance des observations. Lorsque cette hypothèse n'est pas vérifiée, le fonctionnement du filtre peut ne pas correspondre au fonctionnement attendu. Nous distinguons deux types de problème dus à la corrélation des données : l'état des cibles corrélées, et la détection de cible corrélées, nous nous concentrons dans notre travail sur le deuxième problème de corrélation.

En effet, le pistage de cibles pré-pistées conduit à une estimation d'état trop confiante (surconvergence). Ce premier problème de corrélation peut être résolu grâce à la méthode de *information matrix fusion method* présentée en [1].

Dans la suite, nous développons la solution apportée au second problème de corrélation, celui concernant la détection. Typiquement, ce problème correspond à l'exemple suivant : une cible est détectée et pistée depuis un certain temps, cette cible arrive dans une zone de détection difficile pour le capteur (avec une faible probabilité de détection). Or comme cette cible est pistée, le capteur va continuer à la maintenir. Ce problème est particulièrement important avec le filtre GMCPHD, car il peut conduire à une fausse estimation de la probabilité de détection des cibles.

Dans les sections précédentes, nous avons expliqué comment nous estimons la probabilité de détection à partir des performances des capteurs, mais aussi, dans le cas de capteurs optiques, à partir de la position de l'ensemble des cibles (phénomène d'occultation).

Lorsque l'estimation de la probabilité de détection est erronée, plus exactement lorsqu'elle est sous estimée, cela peut introduire une erreur importante dans l'estimation du nombre de cibles par le filtre GMCPHD. En effet, lorsque la probabilité de détection est estimée à n ($n \in [0, 1]$) et que la cible est malgré tout détectée (sur plusieurs instants d'acquisition consécutifs), le nombre de cibles va tendre vers $1/n$. Par exemple, nous observons 1 cible, et la probabilité de détection est estimée à 0.5. La cible est malgré tout détectée consécutivement sur plusieurs instants d'acquisition, le filtre va en fait considérer qu'il y a 2 cibles détectées une fois sur deux ($P_d = 0.5$), ce qui produit 1 détection à chaque instant. L'estimation du

nombre de cibles va donc tendre vers $2 = 1/0.5$.

Dans cette section, nous allons donc proposer une méthode pour corriger la probabilité de détection à partir de l'ensemble des observations du capteur pour résoudre ce genre de problème.

4.8.2 Corrélation de probabilité

Chaque gaussienne j du filtre GMCPHD est liée à une valeur Pd_k^j représentant l'estimation de la probabilité de détection de la cible à l'instant k . Auparavant cette valeur était prédite en fonction des performances du capteur et de l'état de l'ensemble des gaussiennes. Cette prédiction est notée $Pdocc_k^j$. On se propose ici de corriger cette prédiction en fonction des mesures renvoyées par le capteur. Soit z_k^j la mesure provenant de la cible représentée par la gaussienne j à l'instant k , et soit z_{k-1}^j la mesure associée à la même cible à l'instant précédent.

Lorsque les mesures sont suffisamment proches, la probabilité de détection à l'instant k n'est plus indépendante de la probabilité de détection à l'instant $k-1$. A l'inverse, si les deux mesures sont très éloignées, on considère que l'innovation est suffisamment importante pour rendre la probabilité de détection indépendante entre deux instants d'acquisition, i.e. le fait que le capteur ait détecté la cible l'instant précédent n'influe pas sur la détection de l'instant présent. La valeur α est définie comme la gaussienne de la distance entre ces deux mesures :

$$\alpha = \exp\left(-\frac{d(z_k^j, z_{k-1}^j)}{2\sigma_\alpha^2}\right)$$

Ainsi $\alpha = 0$ signifie que les deux événements sont indépendants, alors que $\alpha = 1$ correspond à une dépendance totale entre ces deux événements. La probabilité de détection est finalement définie par :

$$Pd_k^j = (1 - \alpha) \cdot Pdocc_k^j + \alpha(\beta \cdot Pd_{k-1}^j + (1 - \beta))$$

Le deuxième terme de l'égalité $\beta \cdot Pd_{k-1}^j + (1 - \beta)$ entre en jeu lorsque l'on considère qu'il y a dépendance avec l'instant d'acquisition précédent (α proche de 1). Il permet un filtrage temporel de l'estimation de la probabilité de détection. Si plusieurs mesures successives d'une même cible sont placées au même endroit, cela augmente la probabilité de détecter encore une fois ce même objet.




FIGURE 4.21 – α est la valeur de la gaussienne calculée à partir de la distance entre la mesure précédente et la mesure actuelle

4.8.3 Implémentation

4.8.3.1 Définition du paramètre α

La valeur α est donc la valeur de la gaussienne de la norme entre deux mesures successives provenant de la cible représentée par la gaussienne j (voir Figure 4.21). En pratique, la difficulté est de retrouver les deux mesures dans le cas du GMCPHD, puisque ce filtre à une vision globale de l'ensemble des mesures et des cibles. Soit Z_{k-1}^j l'ensemble des mesures liées à la gaussienne j au temps $k-1$. Une mesure est dite liée à une gaussienne, si cette gaussienne a été mise à jour à partir de cette mesure ou si elle est le résultat du merging d'une gaussienne mise à jour à partir de cette mesure avec d'autres gaussiennes. Z_k étant l'ensemble des mesures à l'instant k . Pour chaque $z_{i,k} \in Z_k$ nous calculons α par :

$$\alpha = \max_{z_{k-1} \in Z_{k-1}^j} \exp\left(-\frac{d(z_{i,k}, z_{k-1})}{2\sigma_\alpha^2}\right)$$

où $d(z_{i,k}, z_{k-1})$ est la distance de Mahalanobis entre les deux observations afin de prendre en compte le bruit de mesure du capteur.

La valeur associée à la gaussienne j pour l'estimation de la probabilité de détection est :

$$Pd_k^j = \max_{z_{i,k} \in Z_k} Pd_{i,k}^j$$

$Pd_{i,k}^j$ est la valeur corrigée de la probabilité de détection de la cible j par la mesure i .

La définition de α dépend de l'écart type choisi, nommé σ_α (voir Figure 4.21). On considère que tant que $d(z_{i,k}, z_{k-1})$ est assez petit, les deux mesures ont de fortes chances d'appartenir à




FIGURE 4.22 – Exemple de l'évolution de la probabilité de détection pour différentes valeurs de β

la même cible (sans qu'elle ait bougée). Si σ_α est défini trop petit, le risque est de ne pas faire évoluer la probabilité de détection quand il le faudrait. A l'inverse si σ_α est défini trop grand, on risquerait de trop modifier cette valeur même dans les cas où les mesures successives ne correspondent pas à la même cible (notamment dans le cas où les deux cibles sont proches). Nous avons choisi empiriquement $\sigma_\alpha = 2$.

4.8.3.2 Définition du paramètre β

β est alors un paramètre à régler afin de choisir l'importance que l'on veut accorder à l'historique. Pour les cas $\alpha = 1$ successifs, il est important que la valeur de la probabilité de détection augmente rapidement, mais à l'inverse, il ne faut pas que la valeur de la probabilité de détection augmente trop rapidement en cas de fausses alarmes du capteur.

On choisi pour cela d'utiliser $\beta = 0.7$ (Figure 4.22). Cette valeur nous semble être un bon compromis.

4.8.3.3 Étape de Prédiction

Avec cette nouvelle estimation de la probabilité de détection, chaque gaussienne prédite doit être associée avec la probabilité de détection corrigée associée à la gaussienne mère.

Concernant la naissance des cibles, les nouvelles cibles n'ont aucun rapport avec les anciennes cibles, donc le deuxième terme de l'équation n'entre pas en jeu, la valeur α liée à la

mesure créant la nouvelle cible est égale à 0.

Ceci nous permet de conclure sur la description de notre travail. La section suivante présente l'ensemble des résultats justifiant notre travail.

Chapitre 5

Résultats

Sommaire

5.1	Introduction	136
5.2	Véhicule expérimental	137
5.3	Paramètres capteurs du filtre	138
5.4	Apport de la classification au filtre	141
5.5	Apport des occultations	144
5.6	Apport de prise en compte de la corrélation des données capteurs	158
5.7	Résultats quantitatifs du filtre global	161




FIGURE 5.1 – Véhicule utilisé pour les tests

5.1 Introduction

Dans ce chapitre nous allons développer les différents résultats nous permettant d'évaluer les performances de notre filtre.

Nous avons testé notre filtre avec des données réelles provenant d'un Radar et d'une Caméra (voir Figure 5.1). Notre système a été testé dans différentes situations. Dans un premier temps, dans des situations contrôlées afin d'évaluer précisément le comportement de notre système, ainsi que les avantages et les défauts de notre méthode complète. Ces résultats sont montrés dans les premières sections de ce chapitre afin de détailler l'importance des différents sous systèmes utilisés : la gestion du type de cible, l'évaluation de l'impact des paramètres, la gestion des occultations, et la gestion des corrélations. Dans un deuxième temps, notre système de fusion va être évalué globalement en situation réelle de conduite sur autoroute.

5.2 Véhicule expérimental

Pour acquérir les données décrivant des situations réelles de conduite, nous avons utilisé un véhicule d'expérimentation. Ce véhicule est équipé d'un radar, d'une caméra et d'un lidar, tous les trois étant des capteurs intelligents. Les trois capteurs nous renvoient une liste de détections avec pour chaque détection une estimation de la position, de la vitesse et de la classification des cibles. La description plus précise de la caméra et du radar est confidentielle. Le lidar est un lidar IBEO LUX à 4 nappes. Une webcam est aussi installée sur le véhicule afin d'avoir une visualisation des situations observées. La caméra intelligente ne peut pas être utilisée dans ce cadre car l'image n'est pas accessible. Les trois capteurs intelligents, renvoient des estimations placées dans le référentiel véhicule présenté sur la figure 5.1. Il faut savoir concernant le Lidar, que sa position par rapport au véhicule a due être ajustée pour qu'il soit le plus performant possible. Il a été centré par rapport à l'axe Y, et la deuxième nappe la plus basse est positionnée parallèle au sol dans le cas d'un sol plan. Concernant l'utilisation de la webcam, une calibration a été faite, afin d'estimer les paramètres intrinsèques et extrinsèques de la webcam. Cette calibration nous permet de pouvoir projeter sur l'image webcam, les informations provenant des autres capteurs.

Concernant l'architecture électronique du système de perception, le radar et la caméra sont connectés au même CAN (Controller Area Network), le radar est aussi connecté au CAN véhicule afin d'utiliser certaines informations, telles que la vitesse du véhicule. L'acquisition des données lidar et des images webcam se font par deux câbles Ethernet. L'acquisition des données se fait par un ordinateur portable en utilisant le logiciel RTMAPS. Un ordinateur est utilisé pour rejouer les données et tester notre système, cet ordinateur possède un processeur intel Celeron 1,9 GHz .



FIGURE 5.2 – Exemple d’une situation normale de conduite, vue par la webcam

5.3 Paramètres capteurs du filtre

Dans la section 4.6.5, nous avons présenté les résultats nous ayant permis l’identification des paramètres capteurs utilisés par le GMCPHD. L’impact de ces paramètres est ici analysé.


Nous cherchons à savoir l’importance que peut avoir une bonne estimation de ces paramètres, à s’assurer de la pertinence et l’utilité de l’étude précédente, mais aussi à savoir si une estimation de paramètres plus rapide ou plus grossière est possible. Pour le savoir nous avons cherché à étudier l’impact des différents paramètres, dans le cas d’une sous estimation ou d’une sur estimation de ces paramètres.

5.3.1 Bruit affectant l’estimation de position

Une étude a été conduite pour analyser l’impact de l’estimation du bruit sur le filtre GMCPHD. Le cas d’un bruit constant affectant l’estimation de la position longitudinale par la caméra est considéré (cela signifie que le bruit ne dépend pas de la position des cibles). Ce bruit sera tout d’abord sous-estimé, puis sur-estimé (sachant qu’une fonction affine est plus proche de la réalité, voir Figure 4.11).

Lors de la sous estimation du bruit affectant la position longitudinale, l’estimation de l’état des cibles par le filtre a tendance à être dépréciée. Une petite valeur de bruit de mesure implique des difficultés d’association. Le filtre tend alors à considérer deux pistes différentes, une créée par le radar (nommé A), une autre créée par la Caméra (nommé B). Selon le capteur fournissant les données au filtre, le résultat du filtre sur la position de la cible sera la piste A ou B. L’estimation du nombre de cibles par contre n’est pas impactée. Autrement dit le filtre ne fusionne pas les données des deux capteurs, il se contente de les pister séparément.

Lorsque la valeur du bruit de mesure est sur-évaluée, une perte d’information peut être entraînée. Lors de l’étape du Merging du filtre GMCPHD, deux pistes peuvent être représentées par une seule Gaussienne. Ces deux pistes sont fusionnées. En plus de la perte d’information,



(a) Résultats du filtre avec une modélisation de champs de vue Radar binaire, si une cible a un angle avec le capteur inférieur à $\alpha = 5^\circ$, elle sera détectée, sinon elle ne le sera pas. L'estimation du nombre de cibles augmente alors qu'il n'y a que deux voitures devant notre véhicule.

(b) Résultats du filtre avec une modélisation du champs de vue Radar présenté sur la Figure 4.13. Le filtre estime ici correctement le nombre de cibles (2)

FIGURE 5.3 – Estimation du nombre de cibles par le filtre GMCPHD avec différents champs de vue Radar

deux cibles rassemblées sous une seule gaussienne peuvent amener à une fausse estimation du nombre de cibles. Par exemple, dans la situation présentée dans la Figure 5.2, deux voitures sont observées. Les deux pistes représentant les deux voitures sont mélangées. Par ce 'merging', les positions estimées des deux voitures sont mélangées et moins précises, il est alors plus difficile de détecter l'occultation.

Si les valeurs de bruit de mesure proviennent de l'étude de la section 4.6, alors les problèmes évoqués précédemment sont moins fréquents. Sur 10 minutes d'analyse, nous avons repéré une dizaine d'erreurs de ce type, qui n'apparaissent plus avec une bonne estimation.

5.3.2 Probabilité de détection

L'impact d'une mauvaise estimation de la probabilité de détection du Radar est analysé. Le cas où le champ de vue du Radar est défini comme un champ de vue constant est considéré. La définition d'un champ de vue constant est : si l'angle de la cible avec le capteur est compris dans l'intervalle $[-\alpha, \alpha]$, la probabilité de détection est fixée à 0.9, sinon la valeur est fixée à 0.1. Cette définition est une définition classique de champ de vue dans la littérature. Avec cette définition, nous avons remarqué certains mauvais comportements de filtre pour l'analyse des mesures Radar. Pour une valeur élevée de α , si une cible est située dans le champ de vue

sans être détectée par le Radar, alors la probabilité d'existence de la piste représentant la cible va diminuer jusqu'à la disparition de la piste. Inversement, en utilisant une petite valeur de α , l'estimation du nombre de cibles peut augmenter considérablement (voir Figure 5.3a). Plus précisément, si une piste est positionnée hors du champ de vue et si la cible associée est détectée par le Radar (une détection par instant d'acquisition), le filtre va considérer qu'il y a 10 cibles avec une probabilité de détection de 0.1. Pour résumer, la détection d'une cible avec une faible probabilité de détection finit par conduire à une augmentation importante de l'estimation du nombre de cibles.

Finalement l'identification de la probabilité de détection du Radar est une approximation, elle n'est pas parfaite, mais elle a besoin d'être assez proche de la vérité afin de ne pas conduire aux comportements montrés précédemment. En utilisant la probabilité de détection définie sur la Figure 4.13, l'estimation du nombre de cibles par le filtre est meilleure (voir Figure 5.3b).

Nous avons donc montré dans ce paragraphe les différentes modélisations des paramètres utilisés dans ce filtre ainsi que l'importance de cette modélisation. Les sections suivantes présentent des résultats du filtre concernant l'apport des méthodes permettant de gérer différents types de cible, les occultations et les corrélations.


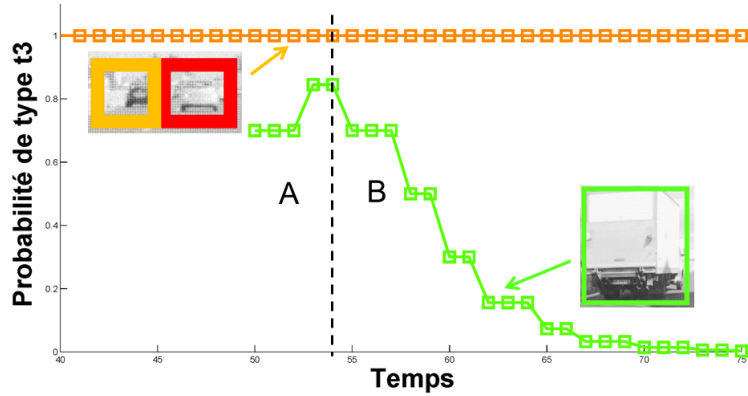


FIGURE 5.4 – Image webcam de la situation : 3 voitures sont détectées

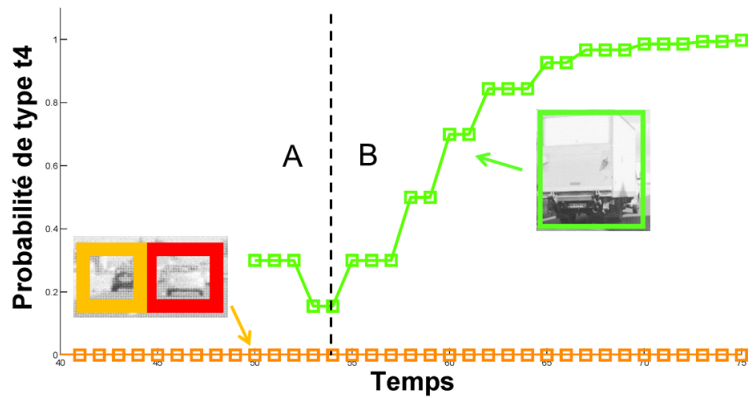
5.4 Apport de la classification au filtre

Dans cette section, le processus de gestion du type de cible est analysé. La Caméra fait la distinction entre les différents types de cibles (piéton, vélos, voiture, camion) alors que le Radar distingue les cibles *mouvantes* (voitures et camions), des cibles *stationnaires* (piétons et vélos). La classification des capteurs n'est pas parfaite et des erreurs de classification peuvent avoir lieu. Un exemple d'erreur est montré sur la Figure 5.4. Cette situation est un exemple intéressant de gestion de type de cible en situation autoroutière. Lorsque le camion commence à être détecté par la caméra, le système de classification de la caméra fait une erreur et classe cet objet comme une voiture pendant trois instants d'acquisition de caméra. Le résultat du radar n'impacte pas la probabilité du type de cible, car il ne distingue pas les objets camion, des objets voiture.

Cet exemple illustre le fait qu'utiliser plusieurs filtres de pistage pour chaque type de cible n'est pas pertinent. La Figure 5.5 montre le résultat de notre filtre concernant l'estimation de la probabilité du type de cible. Grâce à la matrice de confusion caractérisant le système de classification de la Caméra (définie dans la section 4.6.5), l'erreur de classification entre un camion et une voiture est permise. En fait, aussitôt que le résultat du système de classification du capteur change, l'estimation de la probabilité de type de cible change. Si cette erreur a lieu après une longue période de bonne classification, l'estimation du type de cible ne va pas être influencée par l'erreur de classification. Par contre, si l'erreur de classification arrive à la naissance de la piste, plus l'erreur sera longue dans le temps, plus il faudra de temps après le retour de bons résultats de classification pour revenir à une bonne estimation du type de



(a) Probabilité que les pistes soient des voitures




(b) Probabilité que les pistes soient des camions


FIGURE 5.5 – Les probabilités associées à la piste représentant le camion visible sur l’image 5.4 sont représentées en vert sur ces figures, et les probabilités associées aux voitures sont en orange (et en rouge, mais la courbe rouge est cachée par la courbe orange). Pendant les trois premiers instants d’acquisition la caméra détecte le camion comme étant une voiture (zone A), sinon la caméra détecte le camion comme étant un camion (zone B). Cette erreur ne conduit à aucune erreur sur le tracking, la probabilité que le camion vert soit un camion augmente (courbe verte de la figure b).

cible.


Pour conclure, l'ajout de la gestion du type de cible dans notre système de fusion nous permet par exemple de savoir si la cible devant nous est un piéton ou une voiture. Notre méthode probabiliste de l'estimation du type de cible nous permet une gestion des erreurs de classification des capteurs.



(a) Birdview de la situation décrite sur la Figure 4.14 : les mesures capteurs sont représentées par des croix bleues, et les résultats du filtre par des cercles rouges.



(b) Probabilité de détection estimée pour chaque position latérale estimée du piéton.



(c) Nombre estimé de cibles

FIGURE 5.6 – Pendant l'occultation, la position du piéton est prédite et l'estimation du nombre de cibles ne diminue pas.

5.5 Apport des occultations

Pour montrer le fonctionnement de la gestion des occultations, nous l'avons analysé à travers différentes situations de conduite. Ces situations ont été analysées et produites grâce à l'utilisation d'un environnement contrôlé. Les premières situations sont celles utilisant différents types de cible : les occultations de piétons et de voitures. Ensuite, les situations comprenant des occultations d'une voiture par une voiture sont analysées.

5.5.1 Occultation Piéton/Voiture

Des tests en environnement contrôlé ont été réalisés pour analyser l'occultation entre des voitures et des piétons : lorsque le piéton occulte la voiture et lorsque la voiture occulte le piéton. Cette variété de situations est possible grâce au type de cible évalué. En effet, à partir du type de chaque cible, une largeur de cible est évaluée ce qui nous permet de gérer les problèmes d'occultation entre différents types de cible.






FIGURE 5.7 – Exemple d’une situation d’occultation

Un première situation a été évaluée correspondant à la situation décrite par la figure 5.7. Un piéton traverse de droite à gauche en passant derrière une voiture arrêtée. Le radar ne détecte aucune des cibles, la vitesse des cibles étant nulle ou très petite, la gestion des occultations avec les mesures de la caméra prend donc toute son importance. Au début de la séquence, le piéton est classifié comme un piéton, donc la valeur correspondante de la probabilité de détection du radar décroît beaucoup. Ensuite, le piéton est occulté pendant quelques instants, la birdview des positions de chacune des cibles est représentée figure 5.6a. Les positions des objets détectés par la Caméra sont représentées en bleu et celles des pistes du filtre sont représentées en rouge. Pendant l’occultation, la position du piéton est prédite, et l’estimation du nombre de cibles ne diminue pas. Même si le piéton n’est pas détecté pendant un moment, le filtre garde en mémoire qu’il y a bien 2 cibles. Le saut de valeur de l’estimation de la probabilité de détection provient du fait que la valeur de la probabilité de détection est estimée à partir de l’estimation de position de la cible occultée. Or cette estimation de position après plusieurs instants sans correction par une observation est imprécise, d’où le saut de valeur lorsque que la position est de nouveau corrigée.


Un deuxième test de cette même situation est effectué (voir figure 5.8) et comparé au résultats du filtre sans la gestion des occultations (voir figure 5.9). Encore une fois, la position du piéton est prédite pendant l’occultation avec le filtre prenant en compte les occultations et l’estimation du nombre de cibles ne diminue pas. Sans la prise en compte des occultations, le filtre ne se souvient pas de l’existence du piéton lors de son occultation. En effet, la probabilité de détection de la Caméra est de 0.8 pour le piéton, ce qui fait que lorsque que le piéton n’est



(a) Birdview de la situation décrite sur la Figure 5.7 : les mesures capteurs sont représentées par des croix bleues, et les résultats du filtre par des cercles rouges.



(b) Estimation du nombre de cibles. La probabilité d'avoir 2 cibles (resp. 3,1) est représentée en rouge (resp. violet, vert).




(c) Estimation de la probabilité de détection des pistes.

FIGURE 5.8 – Pendant l'occultation, la position du piéton est prédite, et l'estimation du nombre de cibles ne diminue pas.


pas détecté, sa probabilité d'existence diminue.

Ces résultats sont représentatifs de ce qui se passe lors d'occultation avec des cibles non détectées par le radar. Dans ces situations la gestion des occultation est nécessaire pour garder une bonne connaissance de l'environnement.


La figure 5.10 présente un nouvel exemple de scénario d'occultation en situation contrôlée. Deux voitures sont immobiles et un piéton traverse la route au milieu des deux voitures de droite à gauche. Le piéton passe devant la première voiture encadrée en orange et derrière la deuxième voiture encadrée en rouge. Pour cette situation, nous pouvons nous attendre à une première occultation de la voiture orange par le piéton et une deuxième occultation du piéton par la deuxième voiture. Pourtant, lorsque le piéton passe devant la première voiture et que la probabilité de détection de la voiture orange diminue (voir la Figure 5.11b),



(a) Birdview de la situation décrite sur la Figure 4.14 : les mesures capteurs sont représentées par des croix bleues, et les résultats du filtre par des cercles rouges.



(b) Estimation du nombre de cibles. La probabilité d'avoir 2 cibles (resp. 1) est représentée en rouge (resp. violet).



(c) Estimation de la probabilité de détection des pistes.

FIGURE 5.9 – Pendant l'occultation, l'estimation du nombre de cibles diminue.







FIGURE 5.10 – Un piéton de droite à gauche, devant la voiture encadrée en orange, et derrière la voiture encadrée en rouge.



(a) Birdview de la situation décrite sur la Figure 5.10 : Les mesures de capteurs sont représentées en bleu et les résultats du filtre en rouge, orange et vert.



(b) Probabilité de détection estimée pour chaque piste.



(c) Nombre estimé de cibles

FIGURE 5.11 – Pendant l’occultation, la position du piéton est prédite et l’estimation du nombre de cibles ne diminue pas. De plus lorsque le piéton passe devant la voiture orange, la probabilité d’occultation est élevée (ie. la probabilité de détection diminue) et il n’y a pas d’occultation, pourtant le nombre estimé de cibles n’augmente pas.



FIGURE 5.12 – Image webcam de la situation : 2 voitures sont détectées, une voiture change de voie


celle-ci est toujours détectée. Cela ne provoque pas d'erreur dans l'estimation du nombre de cible du filtre, voir Figure 5.11. Cependant, nous pouvons noter une augmentation du bruit affectant la position estimée par la caméra de la voiture orange. En effet, étant partiellement occultée par le piéton, la position de la voiture est moins précise. Le GMCPHD parvient à gérer cette augmentation de bruit mais cela induit une petite diminution de la probabilité d'existence de la cible. De plus, pendant quelques instants la position du piéton est vraiment très proche de la position de la voiture, et grâce à l'utilisation de la probabilité du type de cible pour l'association des cibles et des mesures, il n'y a aucune ambiguïté pour l'association pendant cette période. La deuxième occultation se produit avec la deuxième voiture occultant le piéton, la probabilité de détection du piéton est alors de 0.3. La position du piéton est prédite et l'estimation du nombre de cibles reste à 3. La gestion du type de cible nous permet de gérer cette situation.

5.5.2 Occultations Voiture/Voiture


La Figure 5.12 présente une situation d'occultation d'une voiture par une autre voiture en environnement contrôlé. Une voiture (encadrée en vert) est placée sur la voie de gauche, une autre est placée devant nous (encadrée en rouge), la première voiture change de voie et passe de la gauche à la droite. Plusieurs tests ont été effectués sur ce même scénario, nous présentons dans cette section ceux qui permettent de mettre en évidence certains comportements.

Les voitures sont des cibles routières qui sont détectées normalement par le Radar, nous voyons donc le comportement de la gestion des occultations pour les mesures Caméra lorsque les cibles sont détectées par le Radar (voir Figure 5.13), et lorsqu'elles ne le sont pas (voir Figure 5.14).


La Figure 5.13 montre le résultat de l'un de nos tests. Pour ce test, le Radar est censé détecter les deux cibles (car ce sont des voitures), et le Radar parvient à détecter la voiture occultée (voir Figure 5.13a), la caméra, elle, étant toujours sensible aux occultations ne



(a) Nombre de détections de la Caméra (croix bleues) et nombre de détections Radar (croix vertes) pour la situation décrite dans la Figure 5.12. Le Radar détecte la voiture occultée pendant l'occultation.



(b) Nombre estimé de cibles avec la gestion des occultations. La probabilité d'avoir 2 cibles (resp. 3,1) est représentée en rouge (resp. violet, vert).




(c) Nombre estimé de cibles sans la gestion des occultations. La probabilité d'avoir 2 cibles (resp. 3,1) est représentée en rouge (resp. violet, vert).

FIGURE 5.13 – Pendant l'occultation, la voiture occultée est détectée par le Radar.


détecte pas la voiture occultée. La Figure 5.13b et la Figure 5.13c montrent les résultats du filtre concernant le nombre estimé de cibles avec et sans la gestion des occultations. Ces résultats sont similaires dans les deux cas, l'estimation du nombre de cibles ne diminue pas pendant l'occultation (grâce à la détection du Radar).

La Figure 5.14 montre les résultats d'un autre test. Cette fois le radar ne détecte pas la cible occultée (voir la Figure 5.14a), alors que l'on s'attendait à une détection (les cibles étant des voitures), et la caméra comme la situation précédente ne détecte pas la voiture occultée. La Figure 5.14b montre les résultats des filtres concernant l'estimation du nombre de cibles avec ou sans gestion de l'occultation. Ces résultats sont similaires dans les deux cas mais différents du test montré précédemment Figure 5.13, car cette fois l'estimation du nombre de cible diminue. Cela provient du fait que le radar ne détecte pas la voiture occultée alors que la probabilité de détection ne le laissait pas prévoir (voir l'évaluation de la probabilité de détection Figure 5.14c). Nous pouvons noter tout de même que la diminution du nombre de cibles est moins rapide avec le filtre prenant en compte les occultations.


Pour conclure, dans les situations concernant l'occultation d'une cible détectable par le radar et lors d'une fusion avec le radar (capteur peu sensible aux occultations), la gestion des occultations avec les mesures caméra n'apporte pas de changement au filtre original. Lorsque le radar détecte la cible occultée, le filtre conserve aussi l'existence de la piste associée, et lorsque le radar ne la détecte pas, l'existence de la piste diminue.



(a) Nombre de détections de la Caméra (croix bleues) et nombre de détections Radar (croix vertes) pour la situation décrite dans la Figure 5.12. Le Radar et la Caméra ne détectent pas la voiture occultée pendant l'occultation.



(b) Nombre estimé de cibles avec la gestion des occultations (à gauche) et sans la gestion des occultations (à droite). La probabilité d'avoir 2 cibles (resp.1) est représentée en rouge (resp. vert).



(c) Estimations de la probabilité de détection du filtre avec la gestion des occultations (à gauche) et sans la gestion des occultations (à droite). Celle de la Caméra est représentée en bleue et celle du Radar est représentée en vert. Il y a donc peu de différences entre les résultats.

FIGURE 5.14 – Pendant les occultations, la voiture occultée n'est pas détectée par le radar.



FIGURE 5.15 – Un piéton avance de gauche à droite, devant une voiture puis derrière une autre.


5.5.3 Comparaison avec occultation binaire

Dans cette section, nous montrons l'apport de notre approche comparativement aux approches traditionnelles binaires (voir paragraphe 4.7.3).


Dans la suite, un nouvel exemple de situation d'occultation similaire aux tests de la Figure 5.10 est présenté. Une comparaison est faite entre le fonctionnement et les résultats de différents filtres :

- le filtre classique sans aucune gestion d'occultation,
- le filtre avec une gestion des occultations binaire, méthode basée sur les méthodes typiques de la littérature utilisées avec les données Lidar. Une valeur est assignée à la probabilité de détection. $P_{d_{occ}} \in \{0.1, P_d\}$. Si $x' < (width/2)$ (voir la Figure 4.16 pour la définition de x'), la probabilité est fixée à 0.1, sinon la probabilité affectée à la piste est celle du capteur. Un exemple de carte d'occultation créée avec cette méthode est montré sur la Figure 5.19,
- le filtre avec une gestion des occultations avec la méthode proposée dans ce mémoire, appelé “méthode gaussienne d'occultation”.


La Figure 5.15 présente la situation du test. Les deux voitures sont immobiles et un piéton traverse de gauche à droite devant la première voiture (à gauche) et derrière la deuxième voiture (à droite). Lorsque le piéton passe devant la voiture à gauche, celle-ci est occultée pendant 33 instants d'acquisition. Lorsque le piéton est derrière la voiture de droite, celui-ci est occulté pendant 88 instants d'acquisition. Les résultats produits par les différents filtres sont représentés sur la Figure 5.18. Il n'y a pas de différence entre les méthodes concernant la position estimée, mais il y a des différences entre les méthodes concernant la probabilité d'existence des cibles, en d'autres mots, concernant l'estimation du nombre de cibles (voir Figure 5.17). Sans la gestion des occultations (en rouge), dès que le nombre de détections Caméra diminue (dûe aux occultations), le nombre estimé de cibles diminue de la même façon.



(a) Résultats du filtre sans gestion des occultations.



(b) Résultats du filtre avec une gestion binaire des occultations.



(c) Résultats du filtre avec une gestion gaussienne des occultations.

FIGURE 5.16 – Les points rouges correspondent à la probabilité de détection du piéton, les points marron (resp. vert) correspondent à la probabilité de détection de la voiture droite (resp. gauche). Dans la figure (a) les points marron sont cachés derrière les points vert.







FIGURE 5.17 – Estimation du nombre de cibles par le filtre : les croix noires correspondent aux détections de la caméra (pour cette situation le Radar ne détecte aucune cible), les résultats du filtre sans gestion d'occultation sont représentés en rouge, les résultats du filtre avec une gestion binaire des occultations en bleu, les résultats du filtre avec gestion gaussienne des occultations en verts.



(a) Résultats du filtre sans gestion des occultations.



(b) Résultats du filtre avec une gestion binaire des occultations.



(c) Résultats du filtre avec une gestion gaussienne des occultations.

FIGURE 5.18 – Les mesures de capteurs sont représentées en bleu et les résultats du filtre en rouge.




FIGURE 5.19 – La zone rouge correspond à la zone occultée ($P_{d_{occ}} = 0.1$), sinon la probabilité est celle du capteur $P_{d_{occ}} = P_d$.

Concernant le filtre avec une gestion binaire des occultations, deux comportements peuvent être notés. Dans le premier cas, la largeur de la voiture de gauche, appelée voiture “verte” (celle de gauche est alors appelée voiture “marron”) pour plus de facilité, est sur-évaluée. Pendant 3 instants d’acquisition de la Caméra, une occultation est prédite, alors que la voiture est toujours détectée. La probabilité de détection de la voiture verte est égale à 0.1, associée avec une détection de la voiture, donc l’estimation du nombre de cibles augmente (elle tend vers la valeur 4). Mais dès que la voiture n’est plus détectée, l’estimation du nombre de cibles diminue pour tendre vers 3 cibles.

Le deuxième comportement à noter concerne la deuxième occultation (le piéton derrière la voiture marron), dans ce cas, la zone d’occultation est sous-estimée. La probabilité de détection du piéton est toujours à 0.9, alors que le piéton n’est pas détecté. La probabilité d’existence du piéton diminue alors.

Avec notre méthode, les deux occultations sont résolues et il n’y a pas de changement dans l’estimation du nombre de cibles. La probabilité de détection de la voiture verte est montrée en vert sur la Figure 5.16. Avec la voiture marron, le piéton est occulté pendant quelques instants, et la probabilité de détection est en dessous de 0.3, la position du piéton est prédite, et l’estimation du nombre de cibles reste à 3.

La principale différence de valeur de l'estimation de la probabilité de détection entre deux instants est due à l'erreur de position du piéton pendant l'occultation.

Pour conclure ce paragraphe, nous avons présenté différents tests de différents scénarios : des occultations de voitures par une autre voiture, des occultations de piétons par des voitures et des occultations de voitures par d'autres piétons. Notre méthode permet de garder une estimation correcte du nombre de pistes lors de non-détections dues aux occultations, mais aussi, lorsqu'une non-détection est attendue mais que l'occultation ne se produit pas. De plus nous avons comparé notre méthode aux méthodes sans gestion des occultations ou avec une gestion différente.

Nous pouvons cependant remarquer quelques défauts à cette méthode. Elle est basée sur la position prédite des cibles occultées. Il ne faut donc pas que le comportement de la cible change pendant l'occultation. Par exemple l'instant de réapparition est important : si la cible réapparaît plus tôt que prévu, le filtre réagit bien, le GMCPHD réagissant bien aux importantes différences entre l'état estimé d'une piste et une mesure. Par contre si la cible réapparaît plus tard que prévu, la piste peut disparaître.



FIGURE 5.20 – Image Web-cam : 5 piétons sont détectés par la Caméra.

5.6 Apport de prise en compte de la corrélation des données capteurs

5.6.1 Exemple de situation contrôlée

Ce paragraphe présente un exemple qui permet d'illustrer les problèmes de la corrélation des données, c'est à dire lorsque les données capteurs ne sont plus indépendante d'un instant à l'autre (voir la section 4.8). Notre véhicule est immobile, ainsi que les 5 piétons observés, la corrélation des données sera donc importante puisque il n'y a aucune innovation, tous les acteurs étant immobile.

La probabilité de détection de la Caméra pour un piéton est de 0.8 (et 0 avec le Radar). Pourtant, chaque piéton est toujours détecté par la Caméra, et sans la gestion de la corrélation, l'estimation du nombre de cibles tendrait vers $5 \times \frac{1}{0.8} = 6.25$ (voir le paragraphe 4.8.1), ce résultat est montré par la courbe rouge représentée sur la Figure 5.21). Cela peut créer une fausse alarme puisque que le filtre est à la recherche de 6 cibles alors qu'il n'y en a que 5.

Avec la gestion de la corrélation, le problème est résolu et l'estimation du nombre de cibles tend vers 5 cibles (courbe bleue représentée sur la Figure 5.21).

5.6.2 Exemple sur un cas d'occultation

Nous reprenons un exemple de la section précédente pour mieux comprendre le fonctionnement du filtre avec la gestion des corrélations en situation normale (c'est à dire en situation non réfléchiée par rapport aux corrélations). La situation analysée est celle décrite dans la Figure 5.15 et les résultats sont montré sur la Figure 5.22. Concernant la position






FIGURE 5.21 – les résultats du filtre avec la gestion de la corrélation sont représentés en bleu, ceux sans la gestion de la corrélation sont représentés en rouge. Les croix noires correspondent aux nombre de mesures de la Caméra.

des pistes et l'estimation du nombre de pistes, le résultat est similaire au résultat du filtre sans la gestion des corrélations (voir Figures 5.18c et 5.17, à comparer avec la Figure 5.22). Par contre une différence existe dans l'estimation de la probabilité de détection. Quand une cible est détectée, la probabilité de détection augmente, alors que, dès qu'une cible n'est plus détectée, la probabilité de détection est définie par la prédiction de la probabilité de détection (la valeur de la probabilité de détection sans gestion de la corrélation).


Pour conclure, la correction de la probabilité de détection nous permet de résoudre le problème de la corrélation de détection avec le filtre GMCPHD (création de fausses alarmes intempestives avec une mauvaise estimation du nombre de cibles), et le comportement en situation normale du filtre n'est pas changé.



(a) Birdview de la situation décrite sur la Figure 5.15 : Les mesures de capteurs sont représentées en bleues et les résultats du filtre en rouge, orange et vert.



(b) Nombre estimé de cibles



(c) Probabilité de détection estimée pour chaque piste. les points rouges correspondent à la probabilité de détection du piéton, les points verts (resp. orange) à la probabilité de détection de la voiture de gauche (resp. droite).

FIGURE 5.22 – (à comparer avec les résultats des Figure 5.16c, 5.18c et la courbe verte de la Figure 5.17).

5.7 Résultats quantitatifs du filtre global

En plus des résultats obtenus à partir de situation contrôlée, nous avons voulu évaluer notre système sans a priori de situation. De plus, nous souhaitons vérifier un postulat simple, mais pas évident à évaluer, à savoir, notre système de fusion a-t-il des meilleurs résultats que nos capteurs. Notre méthode a été évaluée avec la gestion du type de cible, la gestion des occultations et la gestion des corrélations. Ces résultats nous permettent aussi de vérifier les performances temps réel de notre système. Le radar émet à une fréquence de 30 Hz et la Caméra à une fréquence de 11Hz.

5.7.1 Exemple de situation réelle

Notre système a été testé en situation réelle pour vérifier plusieurs conclusions. Premièrement, ni la gestion des occultations, ni celle des corrélations ne produit une augmentation du nombre de fausses alarmes. Le cas où un des capteurs détecte une cible alors que l'autre ne la détecte pas est analysé. Les champs de vue des capteurs sont différents. Lorsqu'une voiture nous dépasse par la gauche, la Caméra est la première à la détecter (Figure 5.23a) et le Radar ne la détecte pas (Figure 5.23b). Avec l'étude des capteurs, nous savons que la probabilité du Radar de détecter une cible est environ égale à 0.2 alors que la probabilité de détection de la Caméra est de 0.95. Donc, plusieurs détections de la Caméra sans détection Radar conduisent quand même à la naissance de la cible (Figure 5.23c).

5.7.2 Comparaison vérité terrain

Concernant l'obtention de performances globales du filtre, nous avons cherché à évaluer les performances du filtre concernant la précision et la détection. Pour cela, nous avons comparé les résultats du filtre avec notre vérité terrain créée avec la méthode expliquée dans la section 4.6. A chaque instant d'acquisition, chaque piste est comparée à un objet de la vérité terrain. Comme pour la méthode décrite dans la section 4.6, une première phase d'association automatique est réalisée et ensuite un superviseur humain vérifie les associations manuellement.

Les résultats présentés dans la suite proviennent de l'étude de 10 minutes de test sur autoroute. Plus de 33000 objets à détecter par le filtre sont analysées sur 17000 temps d'acquisition. Deux types de résultats sont donc analysés : l'impact sur la précision de position est évalué puis l'impact sur les performances de détection. Pour le premier critère, les performances sont évaluées vis à vis de moyenne de distance quadratique d'erreur entre la position



(a)



(b)



(c)

FIGURE 5.23 – (a), (b) et (c) sont des images successives de webcam d’une situation réelle. Les détections de la Caméra (resp. Radar) sont représentées avec des croix bleues (resp. vertes) et les résultats du filtre sont montrés en rouge.

	Radar	Camera	Système de fusion
Moyenne de RMSE (m)	1,96	3,5	1,79

TABLE 5.1 – Moyenne de la distance quadratique entre la position estimée et la position de l’objet de vérité terrain en deux dimensions (latérale et longitudinale)

	Radar	Caméra	Système de fusion
Taux de détection (%)	72,3	77,8	80,3
Nombre de fausses alarmes	781	145	68
Nombre d’acquisitions	6157	6157	17000
Nombre de détections	12831	13594	27159

TABLE 5.2 – Performances de détection du système de fusion comparé aux détections des capteurs (nombre de fausses alarmes et taux de détection sont analysés).

de la cible estimée par le capteur (ou le filtre) et les positions des objets de vérité terrain. Le résultat est montré dans le Tableau 5.1. Nous pouvons voir que le système de fusion permet d’améliorer la précision d’estimation de position des cibles.

Le second critère analysé concerne les performances de détection. Le nombre de fausses alarmes, et le taux de détection des capteurs et du filtre sont montrés dans le Tableau 5.2. Le nombre de fausses alarmes est défini par : pour un instant d’acquisition, dès que le capteur (ou le système de fusion) détecte un objet non associé à la vérité terrain, la détection est comptée comme une fausse alarme. Les chiffres présentés dans le tableau peuvent sembler importants, mais il faut relativiser par rapport aux applications. Avec la fréquence de nos capteurs, 70 fausses alarmes consécutives peuvent représenter 1 faux objet pendant 1.5 seconde détecté par les deux capteurs. Cependant, le système de fusion est lui évalué sur l’ensemble des temps d’acquisition (ceux de la Caméra plus ceux du Radar) et nous pouvons noter que la fusion produit une diminution du nombre de fausses alarmes.

Le deuxième critère sur les performances est le taux de détection. Le taux de détection est le ratio entre le nombre de détections du capteur (ou du système de fusion) et du nombre total d’objets de la vérité terrain.

Les chiffres du tableau sont dus au champ de vue de l’étude. Chaque objet de la vérité terrain est compté même s’il est hors du champ de vue des deux capteurs évalués. Le taux de détection est seulement utilisé pour donner une idée comparative entre les capteurs et le système de fusion.

Ces résultats ne sont pas utiles en soit dans le cadre d’une utilisation mais peuvent donner une idée comparative des performances. Ces outils d’évaluation peuvent être aussi utilisés pour comparer différents systèmes de fusion.




FIGURE 5.24 – Visualisation du temps moyen utilisé par le filtre (en rouge, 97.8%), par le traitement des occultations (en bleu, 0.003%), par le traitement des corrélations (en vert 2.2%).

Cette étude nous aura aussi permis de vérifier le caractère temps réel de notre système. Le temps de calcul moyen est de $5.976ms$, dont $5.8422ms$ proviennent du filtre classique GMCPHD, $0.1865\mu s$ sont dues au traitement des occultations et $0.1336ms$ sont dues au traitement de la corrélation (voir Figure 5.24). Le temps de calcul est constant avec le GMCPHD (nombre maximum de gaussiennes utilisées) mais non avec la gestion des occultations ou de la corrélation. Mais les tests effectués nous ont permis de vérifier que notre algorithme est temps réel pour au moins 8 cibles.

Chapitre 6

Conclusion générale et perspective

Sommaire

6.1	Conclusion	166
6.2	Perspectives	168

6.1 Conclusion

Compte tenu de l'augmentation du nombre de voitures utilisant des systèmes ADAS, et de la fiabilité demandée à ces systèmes, les systèmes multi-capteurs sont devenus nécessaires et de plus en plus étudiés. Notre objectif dans cette thèse a été de concevoir un système de perception de l'environnement frontal de notre véhicule qui respecte les contraintes de l'industrie automobile (faible coût, fonctionnement temps réel, et de bonnes performances de détection : très peu de fausses alarmes, et le moins de non détections possibles). Le but de ce système est d'analyser la scène à l'avant du véhicule et d'en extraire les entités routières, telles que les piétons, les vélos, les camions et les voitures. Nous avons donc conçu un système de fusion centralisée modulaire radar/caméra pour la perception de l'environnement. Cette modularité est nécessaire pour l'industrie afin de pouvoir facilement changer de capteur si besoin, elle est permise grâce à l'utilisation de capteurs intelligents ayant une sortie définie et similaire. Nous avons limité la perte d'information liée à la synchronisation en utilisant directement les données des capteurs asynchrones. Le moteur de fusion est construit à partir d'un filtre de pistage utilisant la théorie des probabilités.

En effet après une étude bibliographique sur les systèmes de pistage existant, nous avons comparé ceux qui, a priori permettaient de gérer l'ensemble des problèmes inhérents à nos capteurs et applications. Notre choix s'est ensuite porté sur un filtre de pistage en particulier : le GMCPHD. Nous avons alors conduit une étude pour bien comprendre le fonctionnement et l'ensemble de paramètres impactant ce filtre. Nous avons aussi étendu l'espace d'état du filtre de pistage classique afin d'introduire une information de type de cible en fusionnant les classifications capteur existantes. Cet ajout nous permet de connaître le type de cible placée devant le véhicule. Le résultat de la fusion bayésienne de classifieur est aussi utilisé pour améliorer les performances d'association du filtre. Pour compléter la modularité naturelle du filtre, nous avons défini la procédure permettant de caractériser l'ensemble des paramètres du filtre à modifier en cas de nouveaux capteurs. Pour cela nous avons créé un logiciel permettant la création d'une vérité terrain de situation normale de conduite, pour ensuite la comparer aux résultats des capteurs.

L'un de nos capteurs utilisés étant une caméra, nous avons été amenés à gérer explicitement les occultations dans notre système de fusion. Notre système nous permet de gérer les occultations en prenant en compte les incertitudes concernant la position estimée des obstacles routiers, leur largeur ainsi que l'incertitude d'occultation de la caméra. Des résultats ont été collectés pour assurer le bon fonctionnement de cette gestion, provenant de situations

simples à plus complexes. Nous avons aussi introduit dans ce système, une gestion particulière de la corrélation des données lors de l'utilisation de capteurs intelligents ou lors de situations observées peu innovantes.

Une grande partie de notre travail a consisté à étudier ce filtre avec des données récoltées à partir d'un véhicule de test équipé d'un lidar, d'une caméra et d'un radar. Ces résultats nous ont permis de valider certains comportements de notre système de fusion. Nous avons cherché à valider et à montrer l'intérêt de chacun des différents sous-systèmes de notre système de fusion. Globalement les résultats collectés sont très satisfaisants, même si certaines améliorations sont possibles et décrites dans la section suivante. Contrairement à d'autre systèmes de la littérature, celui que nous avons proposé ne nécessite pas le réglage d'un nombre important de seuils. Nous avons pu ainsi développer une approche globale qui pourrait s'appliquer à un ensemble d'applications ADAS. Nous aboutissons à un système générique et flexible dont nous avons montré la pertinence.

6.2 Perspectives

Le travail engagé dans cette thèse peut être poursuivi dans plusieurs directions. Chez Renault la priorité est d'aboutir à une solution industrialisable, c'est à dire fiable, temps réel et à bas coût. Les aspects temps réel peuvent être approfondis par un portage de la solution proposée sur un calculateur automobile. La fiabilité du système peut, quant à elle, être validée ou réfutée par une évaluation différente du système. En effet, pour Renault, une évaluation applicative peut avoir plus d'intérêt qu'une évaluation globale telle que nous l'avons pour l'instant effectuée. Concernant l'évaluation globale, il pourrait aussi être intéressant d'acquérir de nouvelles données pour s'assurer du comportement de notre système.

D'un point de vue scientifique, ce travail peut aussi progresser sous différentes formes décrites dans la suite.

6.2.1 Amélioration de la prédiction d'état

Dans notre travail nous nous sommes surtout attachés à améliorer l'estimation du nombre de cibles (par la gestion des occultations, et de la corrélation), car pour l'industrie, une fausse alarme ou une non détection peuvent être dangereuses dans les systèmes actifs. Des travaux auraient pu être faits concernant l'état de nos cibles. Plusieurs idées peuvent être exploitées dans ce sens. La première étant d'exploiter différents modèles en fonction du type de la cible. Cette idée a déjà été exploitée dans la littérature [63]. En effet, un piéton n'a pas le même comportement qu'une voiture. Le mouvement d'un piéton est plus aléatoire, alors que celui d'une voiture est plus contraint. Un IMM (*Interacting multiple model*) [80, 62] pourrait être mis en place, avec un modèle différent pour chaque type de cible. La difficulté serait alors de vérifier que le temps de calcul resterait suffisamment petit pour que le système reste temps réel.

Le modèle associé à la voiture pourrait aussi être amélioré par rapport à un modèle classique de voiture en utilisant les informations de carte. En effet, la plupart des voitures sont maintenant équipées d'une antenne GPS. En utilisant les techniques existantes de *Map Matching* [34, 7], nous pouvons en utilisant la position GPS de notre véhicule, en déduire la position sur la carte routière. A partir de la position sur la carte nous pouvons en déduire la position sur la carte des voitures observées. Il faut faire attention de prendre en compte les incertitudes de position, l'incertitude due au GPS [49], l'incertitude liée au Map Matching, l'incertitude liée aux erreurs de carte [130, 129], et l'incertitude due au pistage des cibles. A partir de la position de carte des voitures et de l'information de courbure de route, nous

pouvons contraindre la prédiction de position des cibles en utilisant un modèle contraint tel qu'il a été utilisé dans [82]. Cette nouvelle gestion de modèle cinématique du véhicule pourrait grandement améliorer la prédiction de position de nos cibles, surtout lors des occultations. En effet pendant les occultations, la position de la cible occultée est uniquement prédite, cette gestion serait donc utile.

6.2.2 Fusion caméra radar GPS

Comme nous l'avons dit précédemment, l'utilisation de la position GPS pourrait améliorer la prédiction de l'état des cibles. Mais elle pourrait aussi être utilisée pour préciser la naissance et la mort des cibles. Prenons un exemple, le fait qu'un vélo apparaissent en plein milieu de l'autoroute est hautement improbable. De même il est possible de prévoir l'apparition de nouvelle cible lors des entrées d'autoroute, et la mort des cibles doit a priori se passer aux sorties de l'autoroute. L'ensemble de ces informations étant présentes dans les cartes de navigation classiques, elles pourraient donc être utilisées pour contraindre la naissance et la mort de certaines cibles en fonction de leur type. En allant plus loin, certaines informations qui, pour l'instant, ne figurent pas dans les cartes classiques pourraient être rajoutées et utilisées, telles que la présence d'écoles, de passages piétons... Ces informations pourraient être utilisées pour décrire des zones à haute probabilité d'apparition de piétons.

Bibliographie

- [1] Michael Aeberhard, Andreas Rauch, Marcin Rabiega, Nico Kaempchen, and Torsten Bertram. Track-to-track fusion with asynchronous sensors and out-of-sequence tracks using information matrix fusion for advanced driver assistance systems. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 1–6, 2012.
- [2] Nicolás Amézquita, René Alquézar, and Francesc Serratos. Dealing with occlusion in a probabilistic object tracking method. In *Computer Vision and Pattern Recognition Workshops, 2008. CVPRW '08. IEEE Computer Society Conference on*, pages 1 –8, june 2008.
- [3] Olivier Aycard, Anne Spalanzani, Julien Burlet, Chiara Fulgenzi, Trung Dung Vu, David Raulo, and Manuel Yguel. Pedestrians tracking using offboard cameras. In *Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on*, pages 513 –518, oct. 2006.
- [4] Yaakov Bar-Shalom and Edison Tse. Tracking in a cluttered environment with probabilistic data association. *Automatica*, 11(5) :451–460, 1975.
- [5] Samuel S Blackman. Multiple-target tracking with radar applications. *Dedham, MA, Artech House, Inc., 1986, 463 p.*, 1, 1986.
- [6] Isabelle Bloch. Fusion d informations en traitement du signal et des images. *Hermes Science Publication*, Janvier 2003.
- [7] Sotiris Brakatsoulas, Dieter Pfoser, Randall Salas, and Carola Wenk. On map-matching vehicle tracking data. In *Proceedings of the 31st international conference on Very large data bases*, pages 853–864. VLDB Endowment, 2005.
- [8] Guillaume Bresson, Romuald Aufrere, and Roland Chapuis. Consistent multi-robot

- decentralized slam with unknown initial positions. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 372–379. IEEE, 2013.
- [9] Ho Keong Chan, Hian Beng Lee, Xuhong Xiao, and M. Ulmke. Integrated gmti radar and report tracking for ground surveillance. In *Information Fusion (FUSION), 2010 13th Conference on*, pages 1–7, july 2010.
- [10] Yuan-Lin Chen, Shun-Chung Wang, and Chong-An Wang. Study on vehicle safety distance warning system. In *Industrial Technology, 2008. ICIT 2008. IEEE International Conference on*, pages 1–6. IEEE, 2008.
- [11] Wolfgang Koch Christoph Degen, Felix Govaers. Emitter localization under multipath propagation using smc-intensity filters. In *Information Fusion, 2013 16th International Conference on*, 2013.
- [12] Daniel Clark and Ba-Ngu Vo. Convergence analysis of the gaussian mixture phd filter. *Signal Processing, IEEE Transactions on*, 55(4) :1204–1212, 2007.
- [13] Anders Dahlbom and Per-Johan Nordlund. Detection of hostile aircraft behaviors using dynamic bayesian networks. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 2033–2040. IEEE, 2013.
- [14] Navneet Dalal and Bill Triggs. Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 886–893. IEEE, 2005.
- [15] Belur V Dasarathy. Sensor fusion potential exploitation-innovative architectures and illustrative applications. *Proceedings of the IEEE*, 85(1) :24–38, 1997.
- [16] E Roy Davies. *Machine vision : theory, algorithms, practicalities*. Elsevier, 2004.
- [17] George C Demos, Roberto A Ribas, Ted J Broida, and Samuel S Blackman. Applications of mht to dim moving targets. In *OE/LASE'90, 14-19 Jan., Los Angeles, CA*, pages 297–309. International Society for Optics and Photonics, 1990.
- [18] Arthur P Dempster. Upper and lower probabilities induced by a multivalued mapping. *The annals of mathematical statistics*, 38(2) :325–339, 1967.
- [19] Jean Dezert. Introduction au pistage multi-cibles multi-senseurs. *Rapport technique, Cours ENSTA*, 49 :55–56.

- [20] Jean Dezert. Foundations for a new theory of plausible and paradoxical reasoning. *Information and Security*, 9 :13–57, 2002.
- [21] Jean Dezert and Florentin Smarandache. Fusion of imprecise, uncertain, and conflicting beliefs with dsm rules of combination. *arXiv preprint math/0404305*, 2004.
- [22] Didier Dubois and Henri Prade. Combination of fuzzy information in the framework of possibility theory. *Data fusion in robotics and machine intelligence*, (12) :481–505, 1992.
- [23] Didier Dubois and Henri Prade. La fusion d’informations imprécises. *TS. Traitement du signal*, 11(6) :447–458, 1994.
- [24] Didier Dubois and Henri Prade. Théorie des possibilités. *Masson*, Novembre 1987.
- [25] Didier Dubois and Henri Prade. Representation and combination of uncertainty with belief functions and possibility measures. *Computational Intelligence*, 4(3) :244–264, 1988.
- [26] Ozgur Erdinc, P Willett, and Yaakov Bar-Shalom. Probability hypothesis density filter for multitarget multisensor tracking. In *Information Fusion, 2005 8th International Conference on*, volume 1, pages 8 pp.–, 2005.
- [27] Tina Erlandsson and Lars Niklasson. Threat assessment for missions in hostile territory-from the aircraft perspective. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 1856–1862. IEEE, 2013.
- [28] Azim Eskandarian. *Handbook of Intelligent Vehicles*. Springer, 2012.
- [29] Meng Fanbin, Hao Yanling, Xia Quanxi, OuYang Taishan, and Zou Wei. A particle phd filter for multi-sensor multi-target tracking based on sequential fusion. In *Information Engineering and Computer Science, 2009. ICIECS 2009. International Conference on*, pages 1 –5, dec. 2009.
- [30] Wen Fang and Kap Luk Chan. Learning a new statistical shape prior model for object detection by geodesic active contours. In *Video and Signal Based Surveillance, 2006. AVSS ’06. IEEE International Conference on*, page 42, nov. 2006.

- [31] Fadi Fayad and Veronique Cherfaoui. Tracking objects using a laser scanner in driving situation based on modeling target shape. In *Intelligent Vehicles Symposium, 2007 IEEE*, pages 44–49, june 2007.
- [32] Varun Ganapathi, Christian Plagemann, Daphne Koller, and Sebastian Thrun. Real time motion capture using a single time-of-flight camera. In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on*, pages 755–762. IEEE, 2010.
- [33] Samuel Gidel, Christophe Blanc, Thierry Chateau, Paul Checchin, and Laurent Trassoudaine. Non-parametric laser and video data fusion : Application to pedestrian detection in urban environment. In *Information Fusion, 2009. FUSION'09. 12th International Conference on*, pages 626–632. IEEE, 2009.
- [34] Joshua S Greenfeld. Matching gps observations to locations on a digital map. In *National Research Council (US). Transportation Research Board. Meeting (81st : 2002 : Washington, DC). Preprint CD-ROM*, 2002.
- [35] Xavier Gros. *NDT data fusion*. Access Online via Elsevier, 1996.
- [36] Anselm Haselhoff, Anton Kummert, and Georg Schneider. Radar-vision fusion with an application to car-following using an improved adaboost detection algorithm. In *Intelligent Transportation Systems Conference, 2007. ITSC 2007. IEEE*, pages 854–858, 2007.
- [37] Chen Huazhi and Rong Jian. A multitarget tracking algorithm based on radar and infrared sensor data fusion. In *Communication Software and Networks (ICCSN), 2011 IEEE 3rd International Conference on*, pages 367–371, may 2011.
- [38] Lasse Johansson, Ari Karppinen, and Leo Wanner. The fusion of meteorological-and air quality information for orchestrated services using environmental profiling. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 1638–1644. IEEE, 2013.
- [39] Thomas Kailath. The divergence and bhattacharyya distance measures in signal selection. *Communication Technology, IEEE Transactions on*, 15(1) :52–60, 1967.
- [40] Shunsuke Kamijo, Yasuyuki Matsushita, Katsushi Ikeuchi, and Masao Sakauchi. Occlusion robust tracking utilizing spatio-temporal markov random field model. In *Pattern Recognition, 2000. Proceedings. 15th International Conference on*, volume 1, pages 140–144. IEEE, 2000.

- [41] Takeo Kato, Yoshiki Ninomiya, and Ichiro Masaki. An obstacle detection method by fusion of radar and motion stereo. In *SICE 2003 Annual Conference*, volume 1, pages 689–694, 2003.
- [42] Waqar Khan and John Morris. Safety of stereo driver assistance systems. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 469–475. IEEE, 2012.
- [43] Dieter Koller, Joseph Weber, and Jitendra Malik. Robust multiple car tracking with occlusion reasoning. pages 189–196. Springer-Verlag, 1993.
- [44] Sebastien Kramm and Abdelaziz Bensrhair. Obstacle detection using sparse stereovision and clustering techniques. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 760–765, June 2012.
- [45] Chris Kreucher, Sridhar Lakshmanan, and Karl Kluge. A driver warning system based on the lois lane detection algorithm. In *Proceedings of IEEE International Conference on Intelligent Vehicles*, pages 17–22. Stuttgart, Germany, 1998.
- [46] Ludmila I Kuncheva. Switching between selection and fusion in combining classifiers : An experiment. *Systems, Man, and Cybernetics, Part B : Cybernetics, IEEE Transactions on*, 32(2) :146–156, 2002.
- [47] Ludmila I Kuncheva, James C Bezdek, and Robert PW Duin. Decision templates for multiple classifier fusion : an experimental comparison. *Pattern Recognition*, 34(2) :299–314, 2001.
- [48] Laetitia Lamard, Roland Chapuis, and Jean Philippe Boyer. Multi target tracking with cphd filter based on asynchronous sensors. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 892–898, 2013.
- [49] Olivier Le Marchand. *Approche autonome pour la localisation et la surveillance de l’intégrité d’un véhicule automobile en environnement complexe*. PhD thesis, Université de Technologie de Compiègne, 2010.
- [50] Eric Lefevre, Patrick Vannoorenberghe, and Olivier Colot. Using information criteria in dempster-shafer’s basic belief assignment. In *Fuzzy Systems Conference Proceedings, 1999. FUZZ-IEEE’99. 1999 IEEE International*, volume 1, pages 173–178. IEEE, 1999.

- [51] John Leonard, Jonathan How, Seth Teller, Mitch Berger, Stefan Campbell, Gaston Fiore, Luke Fletcher, Emilio Frazzoli, Albert Huang, Sertac Karaman, et al. A perception-driven autonomous urban vehicle. *Journal of Field Robotics*, 25(10) :727–774, 2008.
- [52] Martin E Liggins, Chee-Yee Chong, Ivan Kadar, Mark G Alford, Vincent Vannicola, Stelios Thomopoulos, et al. Distributed fusion architectures and algorithms for target tracking. *Proceedings of the IEEE*, 85(1) :95–107, 1997.
- [53] Liwei Liu, Genquan Duan, Haizhou Ai, and Shihong Lao. An evaluation of boosted features for vehicle detection. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 956–961. IEEE, 2012.
- [54] Ren C Luo and MG Kay. *Data fusion in robotics and machine intelligence*. Academic Press, 1992.
- [55] Ronald Mahler. Phd filter of higher order in target number. *IEEE Transactions on Aerospace and Electronic Systems*, 43(4), Octobre 2007.
- [56] Ronald Mahler. Phd filters of higher order in target number. *Aerospace and Electronic Systems, IEEE Transactions on*, 43(4) :1523 –1543, october 2007.
- [57] Ronald Mahler. *Statistical Multisource Multitarget Information Fusion*. Artech House, Norwood, MA, 2007.
- [58] Ronald Mahler. Approximate multisensor cphd and phd filters. In *Information Fusion (FUSION), 2010 13th Conference on*, pages 1 –8, july 2010.
- [59] Ronald Mahler and Tim Zajic. Multi-object tracking using a generalized multi-object first-order moment filter. In *Computer Vision and Pattern Recognition Workshop, 2003. CVPRW '03. Conference on*, volume 9, page 99, june 2003.
- [60] Arnaud Martin. La fusion d informations. *Polycopié de cours ENSIETA-Réf*, 1484 :117, 2005.
- [61] Efim Mazor, Amir Averbuch, Yakov Bar-Shalom, and Joshua Dayan. Interacting multiple model methods in target tracking : a survey. *Aerospace and Electronic Systems, IEEE Transactions on*, 34(1) :103–123, Jan 1998.

- [62] Efim Mazor, Amir Averbuch, Yakov Bar-Shalom, and Joshua Dayan. Interacting multiple model methods in target tracking : a survey. *Aerospace and Electronic Systems, IEEE Transactions on*, 34(1) :103–123, 1998.
- [63] Daniel Meissner, Stephan Reuter, Benjamin Wilking, and Klaus Dietmayer. Road user tracking using a dempster-shafer based classifying multiple-model phd filter. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 1236–1242. IEEE, 2013.
- [64] Martin Ulmke Michael Mertens. Ground target tracking with rcs estimation utilizing probability hypothesis density filters. In *Information Fusion, 2013 16th International Conference on*, 2013.
- [65] Julien Moras. *Grilles de perception évidentielles pour la navigation robotique en milieu urbain*. PhD thesis, Université de Technologie de Compiègne, 2013.
- [66] Maximilian Muffert, Timo Milbich, David Pfeiffer, and Uwe Franke. May i enter the roundabout ? a time-to-contact computation based on stereo-vision. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 565–570. IEEE, 2012.
- [67] D. Muller, J. Pauli, M. Meuter, L. Ghosh, and S. Muller-Schneiders. A generic video and radar data fusion system for improved target selection. In *Intelligent Vehicles Symposium (IV), 2011 IEEE*, pages 679–684, 2011.
- [68] Darko Musicki, Robin Evans, and Srdjan Stankovic. Integrated probabilistic data association. *Automatic Control, IEEE Transactions on*, 39(6) :1237–1241, 1994.
- [69] Fawzi Nashashibi and Alexandre Bargeton. Laser-based vehicles tracking and classification using occlusion reasoning and confidence estimation. In *Intelligent Vehicles Symposium, 2008 IEEE*, pages 847 –852, june 2008.
- [70] Estelle Ngako Pangop. *Approche bayésienne de fusion d’informations pour la reconnaissance d’objets routiers : application au cas du piéton*. PhD thesis, Clermont-Ferrand 2, 2009.
- [71] Hung T Nguyen and Elbert A Walker. On decision making using belief functions. *Advances in the Dempster-Shafer theory of evidence*, pages 311–330, 1994.

- [72] Hossein Tehrani Niknejad, Taiki Kawano, Yuki Oishi, and Seiichi Mita. Occlusion handling using discriminative model of trained part templates and conditional random field. In *Intelligent Vehicles Symposium (IV), 2013 IEEE*, pages 750–755. IEEE, 2013.
- [73] Seglo F (2010) HAVEit project deliverable 23.1 Nilsson A, Nilsson P. Brake-by-wire for challenge 4.2. www.haveit-eu.org.
- [74] Franco Oberti, Simona Calcagno, Michela Zara, and Carlo S Regazzoni. Robust tracking of humans and vehicles in cluttered scenes with occlusions. In *Image Processing. 2002. Proceedings. 2002 International Conference on*, volume 3, pages 629–632. IEEE, 2002.
- [75] Daniel Olmeda, Arturo de la Escalera, and Jose Maria Armingol. Contrast invariant features for human detection in far infrared images. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 117–122. IEEE, 2012.
- [76] Co operative systems for road safety. Smart vehicles on smart roads, safespot, fp6 integrated project. <http://www.safespot-eu.org/>.
- [77] Peter Willett Ozgur Erding and Yaakov Bar-Shalom. Bin-occupancy filter and its connection to the phd filter. *IEEE Transactions on Signal Processing*, 57(11), Novembre 2009.
- [78] Markus Pakleppa, Jan Bernd Vorstius, Robert Keatch, Silvia C Tapia-Siles, Stuart Coleman, and Alfred Cuschieri. Dempster-shafer theory applied in state estimation of a pressure driven endoscope for hydro-colonoscopy. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 1413–1420. IEEE, 2013.
- [79] Laurence Ngako Pangop, Frédéric Chausse, Sebastien Cornou, and Roland Chapuis. Adaptive bayesian combination of features from laser scanner and camera for pedestrian detection. In *IFAC Symposium on Intelligent Autonomous Vehicles*, 2007.
- [80] Benjamin Pannetier, Jean Dezert, and Evangeline Pollard. Improvement of multiple ground targets tracking with gmti sensor and fusion of identification attributes. In *Aerospace Conference, 2008 IEEE*, pages 1 –13, march 2008.
- [81] Judea Pearl. *Probabilistic reasoning in intelligent systems : networks of plausible inference*. Morgan Kaufmann, 1988.

- [82] Evangeline Pollard. *Evaluation de situations dynamiques multicibles par fusion de données spatio-temporelles*. PhD thesis, Université de Grenoble, 2008.
- [83] Preventive and FP6 integrated project. active safety applications, PReVENT. <http://www.prevent-ip.org/>.
- [84] Donald B Reid. An algorithm for tracking multiple targets. *Automatic Control, IEEE Transactions on*, 24(6) :843–854, 1979.
- [85] S. Reuter and K. Dietmayer. Pedestrian tracking using random finite sets. In *Information Fusion (FUSION), 2011 Proceedings of the 14th International Conference on*, pages 1–8, july 2011.
- [86] Stephan Reuter, Daniel Meissner, Benjamin Wilking, and Klaus Dietmayer. Cardinality balanced multi-target multi-bernoulli filtering using adaptive birth distributions. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 1608–1615. IEEE, 2013.
- [87] Thorsten Ringbeck and Bianca Hagebeuker. A 3d time of flight camera for object detection. In *Proc. of the 8th Conf. On Optical 3-D Measurement Techniques*, 2007.
- [88] B. Ristic, D. Clark, Ba-Ngu Vo, and Ba-Tuong Vo. Adaptive target birth intensity for phd and cphd filters. *Aerospace and Electronic Systems, IEEE Transactions on*, 48(2) :1656–1668, 2012.
- [89] Branko Ristic and Philippe Smets. Belief function theory on the continuous space with an application to model based classification. In *Proceedings of Information Processing and Management of Uncertainty in Knowledge-Based Systems, IPMU*, pages 4–9, 2004.
- [90] Arunesh Roy, Nicholas Gale, and Lang Hong. Fusion of doppler radar and video information for automated traffic surveillance. In *Information Fusion, 2009. FUSION '09. 12th International Conference on*, pages 1989–1996, 2009.
- [91] Oliver C Schrempf, Olga Feiermann, and Uwe D Hanebeck. Optimal mixture approximation of the product of mixtures. *Proc. 8th Int. Conf. Inf. Fusion*, Jul. 2005.
- [92] Johan Schubert and Anna Linderhed. Decision support from learning multiple boundaries on military operational plans from simulation data. In *Information Fusion (FUSION), 2013 16th International Conference on*, pages 1204–1213. IEEE, 2013.

- [93] Glenn Shafer. *A mathematical theory of evidence*, volume 1. Princeton university press Princeton, 1976.
- [94] Robert W Sittler. An optimal data association problem in surveillance theory. *Military Electronics, IEEE Transactions on*, 8(2) :125–139, 1964.
- [95] Philippe Smets. The combination of evidence in the transferable belief model. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(5) :447–458, 1990.
- [96] Philippe Smets. The α -junctions : combination operators applicable to belief functions. In *Qualitative and quantitative practical reasoning*, pages 131–153. Springer, 1997.
- [97] Philippe Smets. Imperfect information : Imprecision and uncertainty. In *Uncertainty Management in Information Systems*, pages 225–254. Springer, 1997.
- [98] Philippe Smets. Data fusion in the transferable belief model. In *Information Fusion, 2000. FUSION 2000. Proceedings of the Third International Conference on*, volume 1, pages PS21–PS33. IEEE, 2000.
- [99] Philippe Smets. Belief functions : the disjunctive rule of combination and the generalized bayesian theorem. In *Classic Works of the Dempster-Shafer Theory of Belief Functions*, pages 633–664. Springer, 2008.
- [100] A. Sole, O. Mano, G.P. Stein, H. Kumon, Y. Tamatsu, and A. Shashua. Solid or not solid : vision for radar target validation. In *Intelligent Vehicles Symposium, 2004 IEEE*, pages 819–824, 2004.
- [101] Gideon P Stein, Ofer Mano, and Amnon Shashua. A robust method for computing vehicle ego-motion. In *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*, pages 362–368. IEEE, 2000.
- [102] Gideon P Stein, Ofer Mano, and Amnon Shashua. Vision-based acc with a single camera : bounds on range and range rate accuracy. In *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*, pages 120–125, June 2003.
- [103] C. Tessier, C. Cariou, C. Debain, F. Chausse, R. Chapuis, and C. Rousset. A real-time, multi-sensor architecture for fusion of delayed observations : application to vehicle localization. In *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*, pages 1316 –1321, sept. 2006.

- [104] Sebastian Thrun, Mike Montemerlo, Hendrik Dahlkamp, David Stavens, Andrei Aron, James Diebel, Philip Fong, John Gale, Morgan Halpenny, Gabriel Hoffmann, et al. Stanley : The robot that won the darpa grand challenge. *Journal of field Robotics*, 23(9) :661–692, 2006.
- [105] S. Tokoro, K. Kuroda, A. Kawakubo, K. Fujita, and H. Fujinami. Electronically scanned millimeter-wave radar for pre-crash safety and adaptive cruise control system. In *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*, pages 304–309, June 2003.
- [106] Adrien UGON, Jean-Gabriel GANASCIA, Carole PHILIPPE, H  lene AMIEL, and Pierre Levy. Multi-layers symbolic fusion with conceptual graphs to support the sleep apnea syndrome diagnosis.
- [107] Martin Ulmke, Ozgur Erdinc, and Peter Willett. Gaussian mixture cardinalized phd filter for ground moving target tracking. In *Information Fusion, 2007 10th International Conference on*, pages 1–8. IEEE, 2007.
- [108] Martin Ulmke, Ozgur Erdinc, and Peter Willett. Gmti tracking via the gaussian mixture cardinalized probability hypothesis density filter. *Aerospace and Electronic Systems, IEEE Transactions on*, 46(4) :1821–1833, 2010.
- [109] Ardalan Vahidi and Azim Eskandarian. Research advances in intelligent collision avoidance and adaptive cruise control. *Intelligent Transportation Systems, IEEE Transactions on*, 4(3) :143–153, Sept 2003.
- [110] Andrei Vatavu, Radu Danescu, and Sergiu Nedevschi. Real-time dynamic environment perception in driving scenarios using difference fronts. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 717–722. IEEE, 2012.
- [111] Patrick Verlinde, Marc Acheroy, et al. A contribution to multi-modal identity verification using decision fusion. *Department of Automatic Verification*, 1999.
- [112] Damien Vivet. *Perception de l’environnement par radar hyperfr  quence. Application    la localisation et la cartographie simultan  es,    la d  tection et au suivi d’objets mobiles en milieu ext  rieur*. PhD thesis, Universit   Blaise Pascal-Clermont-Ferrand II, 2011.
- [113] B-T Vo, B-N Vo, and Antonio Cantoni. Performance of phd based multi-target filters. In *Information Fusion, 2006 9th International Conference on*, pages 1–8. IEEE, 2006.

- [114] Ba-Ngu Vo and Wing-Kin Ma. The gaussian mixture probability hypothesis density filter. *Signal Processing, IEEE Transactions on*, 54(11) :4091–4104, 2006.
- [115] Ba-Ngu Vo, Sumeetpal Singh, and Arnaud Doucet. Sequential monte carlo methods for multitarget filtering with random finite sets. *Aerospace and Electronic Systems, IEEE Transactions on*, 41(4) :1224–1245, 2005.
- [116] Ba-Tuong Vo, Ba-Ngu Vo, and Antonio Cantoni. The cardinalized probability hypothesis density filter for linear gaussian multi-target models. In *Information Sciences and Systems, 2006 40th Annual Conference on*, pages 681–686. IEEE, 2006.
- [117] Ba-Tuong Vo, Ba-Ngu Vo, and Antonio Cantoni. Analytic implementations of the cardinalized probability hypothesis density filter. *Signal Processing, IEEE Transactions on*, 55(7) :3553–3567, 2007.
- [118] Abraham Wald. *Sequential analysis*. Courier Corporation, 1973.
- [119] Lucien Wald. A european proposal for terms of reference in data fusion. *International Archives of Photogrammetry and Remote Sensing*, 32(7) :651–654, 1998.
- [120] Lucien Wald. Some terms of reference in data fusion. *Geoscience and Remote Sensing, IEEE Transactions on*, 37(3) :1190–1193, 1999.
- [121] Edward Waltz, James Llinas, et al. *Multisensor data fusion*, volume 685. Artech House Norwood, 1990.
- [122] Andreas Wedel and Uwe Franke. Monocular video serves radar-based emergency braking. In *Intelligent Vehicles Symposium, 2007 IEEE*, pages 93–98. IEEE, 2007.
- [123] Xiaoxi Yan Jing Liu Wei Li, Chongzhao Han. Adaptive sequential monte carlo implementation of the phd filter for multi-target tracking. In *Information Fusion, 2013 16th International Conference on*, 2013.
- [124] Bo Wu and Ram Nevatia. Detection and tracking of multiple, partially occluded humans by bayesian combination of edgelet based part detectors. *International Journal of Computer Vision*, 75(2) :247–266, 2007.
- [125] Lei Xu, Adam Krzyzak, and Ching Y Suen. Methods of combining multiple classifiers and their applications to handwriting recognition. *Systems, Man and Cybernetics, IEEE Transactions on*, 22(3) :418–435, 1992.

- [126] Ronald R Yager. On the dempster-shafer framework and new combination rules. *Information sciences*, 41(2) :93–137, 1987.
- [127] Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3) :338–353, 1965.
- [128] Paul Zarchan and Howard Musoff. *Fundamentals of Kalman filtering - a practical approach*. AIAA, 2000.
- [129] Clément Zinoune, Philippe Bonnifait, and Javier Ibanez-Guzman. Detection of missing roundabouts in maps for driving assistance systems. In *Intelligent Vehicles Symposium (IV), 2012 IEEE*, pages 123–128. IEEE, 2012.
- [130] Clément Zinoune, Philippe Bonnifait, and Javier Ibañez-Guzmán. A sequential test for autonomous localisation of map errors for driving assistance systems. In *Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference on*, pages 1377–1382. IEEE, 2012.